

PODACI O DISERTACIJI

I. AUTOR

Ime i prezime	Katarina Tomičić-Pupek
Datum i mjesto rođenja	11.01.1979., Brčko, RBiH
Naziv fakulteta i datum diplomiranja na VII/I stupnju	Fakultet organizacije i informatike Varaždin, 08.03.2003.
Sadašnje zaposlenje	Fakultet organizacije i informatike Varaždin, Asistent

II. DISERTACIJA

Naslov	Sustavi planiranja i upravljanja resursima visokih učilišta
Broj stranica, slika, grafičkih prikaza, tablica, priloga, bibliografskih podataka	242 stranice, 64 slike, 32 tablice, 99 bibliografskih jedinica
Znanstveno područje i polje iz koje je postignut doktorat znanosti	Područje društvenih znanosti, polje informacijskih i komunikacijskih znanosti
Mentor ili voditelj rada	Prof.dr.sc. Vjeran Strahonja
Fakultet na kome je obranjena disertacija	Fakultet organizacije i informatike
Oznaka i redni broj rada	101

III. OCJENA I OBRANA

Datum sjednice Fakultetskog vijeća na kojoj je prihvaćena tema	21.12.2010.
Datum predaje rada	30.04.2011.
Datum sjednice Fakultetskog vijeća na kojoj je rad prihvaćen	05.07.2011.
Sastav Povjerenstva koje je rad ocijenilo	Prof.dr.sc. Josip Brumec Prof.dr.sc. Vesna Bosilj Vukšić Prof.dr.sc. Vjeran Strahonja
Datum obrane rada	17.10.2011.
Sastav Povjerenstva pred kojim je rad obranjen	Prof.dr.sc. Josip Brumec Prof.dr.sc. Vesna Bosilj Vukšić Prof.dr.sc. Vjeran Strahonja
Datum promocije	

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE VARAŽDIN

KATARINA TOMIČIĆ-PUPEK

**SUSTAVI PLANIRANJA I UPRAVLJANJA RESURSIMA VISOKIH
UČILIŠTA**

– DOKTORSKA DISERTACIJA –

VARAŽDIN, 2011.

SVEUČILIŠTE U ZAGREBU

FAKULTET ORGANIZACIJE I INFORMATIKE VARAŽDIN

VODITELJ RADA: Prof.dr.sc. VJERAN STRAHONJA

Predgovor

Ostvarenje misije visokog učilišta se mjeri doprinosom visokoobrazovnom, znanstvenom i stručnom razvoju društva. Reforma sustava visokog obrazovanja i smanjeno ulaganje u znanost rezultiraju zanemarivanjem poslovne učinkovitosti upravljanja resursima radi većeg dobra – društvene koristi. Izazovi u financiranju djelatnosti visokih učilišta ukazuju na nužnost primjena nekih metoda korporativnog upravljanja resursima iz poslovnog sektora na javna visoka učilišta, a sve to radi njihova opstanka u kompetitivnom okruženju. Kako pojedinac, zaposlenik visokog učilišta, može doprinijeti odoljevanju ovom izazovu – pitanje je koje je predstavljalo motivaciju za izradu ovog rada.

Tijekom izrade rada su se pojavljivali raznoliki istraživački i znanstveni izazovi, zato koristim ovu priliku srdačno zahvaliti svima koji su doprinijeli kvaliteti rada: mentoru prof.dr.sc. Vjeranu Strahonji za poticaj, diskusije i dobronamjerne savjete, članovima povjerenstva prof.dr.sc. Vesni Bosilj Vukšić i prof.dr.sc. Josipu Brumecu na konstruktivnim primjedbama, prof.dr.sc. Divjak na materijalima i uputama te prof. Horvatu na instrukcijama iz matematike, Tini i Željku na moralnoj potpori i drugima koje sam zaboravila spomenuti. Moram zahvaliti i svojoj obitelji, suprugu Ninoslavu i sinu Sebastijanu. Iskreno, hvala svima.

Na kraju, umjesto još jedne zahvale, posveta rada čovjeku koji bi se ovome najviše od svih veselio – mom tati.

U Varaždinu, 2011. godine

Autorica

SADRŽAJ

1. Uvod	1
1.1. Predmeti i objekti istraživanja	2
1.2. Pregled dosadašnjih istraživanja i istraživačkih problema	3
1.3. Hipoteze i očekivani znanstveni doprinos	5
2. Utjecaj organizacijskih čimbenika i okruženja na sustav planiranja i upravljanja resursima visokih učilišta	7
2.1. Oblici organizacije i upravljanja visokih učilišta	7
2.2. Financiranje visokih učilišta	13
2.3. Financiranje visokih učilišta u RH	22
2.4. Osnovni resursi visokih učilišta	25
2.5. Primjena metode Balanced Scorecard u upravljanju visokim učilištem	27
2.6. Analiza strukture sustava i okruženja visokih učilišta	30
3. Model poslovnih i akademskih procesa visokih učilišta	51
3.1. Analiza kompletnosti popisa procesa s obzirom na značaj procesa u upravljanju resursima poslovanja	58
3.2. Analiza kompletnosti popisa procesa s obzirom na životni ciklus resursa	60
3.3. Analiza kompletnosti popisa procesa s obzirom na značaj procesa za ostvarenje misije	72
3.4. Model poslovnih i akademskih procesa visokih učilišta	79
4. Usporedba novog modela s postojećim javno dostupnim modelima procesa visokih učilišta	110
4.1. Postojeći javno dostupni modeli procesa visokih učilišta	110
4.1.1. Model procesa visokog učilišta Charles Sturt University	110
4.1.2. Model procesa visokog učilišta Glendale Community College	113
4.1.3. Model procesa visokog učilišta prema JISC	114
4.1.4. Model procesa vezanih uz znanstvene projekte visokog učilišta Oxford Brookes	116
4.1.5. Procesi visokog učilišta Sheffield Hallam	117
4.1.6. Model procesa visokih učilišta mapiran sa SAP rješenjima	119
4.1.7. Procesi visokih učilišta prema modulima Oracle ERP rješenja	123
4.1.8. Model procesa upisa na visoko učilište – pristup vizualnog modeliranja složenih procesa	124
4.2. Usporedna analiza modela procesa	125
4.3. Osvrt na hipotezu mogućnosti izrade referentnog modela planiranja i upravljanja resursima visokih učilišta	128

5.	Sustavi planiranja i upravljanja resursima	131
5.1.	Definicija ERP sustava	131
5.2.	Klasifikacija ERP sustava	134
5.3.	Metodike uvođenja ERP sustava	138
5.4.	Preporuke najbolje svjetske prakse uvođenja ERP sustava za visoko obrazovanje	144
6.	Podaci i moduli ERP sustava za visoka učilišta	146
6.1.	Matrica poslovne tehnologije	146
6.2.	Model podataka ERP sustav za visoka učilišta	149
6.3.	Moduli ERP sustava za visoka učilišta	153
7.	Osnovni koncepti ERP sustava visokih učilišta	162
7.1.	Polazna teza o sličnosti koncepata	162
7.2.	Modeli osnovnih koncepata ERP sustava	164
7.3.	Određivanje semantičke sličnosti	168
7.4.	Određivanje strukturne sličnosti	171
7.4.1.	Definicije osnovnih pojmova	172
7.4.2.	Postupak određivanja strukturne sličnosti istovrsnih grafičkih modela	173
7.4.2.1.	Priprema grafičkih modela	180
7.4.2.2.	Primjena algoritma usporedbe grafova	193
7.4.2.3.	Tumačenje rezultata usporedbe	201
7.4.3.	Ograničenja, rizici i inačice postupka određivanja strukturne sličnosti istovrsnih grafičkih modela	209
7.5.	Osvrt na hipotezu o semantičkoj i strukturnoj sličnosti koncepata ERP sustava	212
8.	Interoperabilnost ERP sustava i integracija s drugim informacijskim (pod)sustavima	214
8.1.	Definicija i razine interoperabilnosti	214
8.2.	Interoperabilnost ERP-a za visoka učilišta	217
8.3.	Integracijsko procesno i podatkovno sučelje ERP sustava visokih učilišta i drugih informacijskih podsustava	223
9.	Zaključak	229
	Bibliografija	

POPIS SLIKA

<i>Slika 2.1.: Grafički prikaz učestalosti odgovora na pitanje važnosti oblika promjene za visoko učilište u posljednjih 10 godina</i>	12
<i>Slika 2.2.: Grafički prikaz učestalosti odgovora na pitanje odabira tri najvažnija napora u promjenama vezanim uz financiranje na vlastitom visokom učilištu</i>	13
<i>Slika 2.3.: Izvori financiranja visokih učilišta</i>	15
<i>Slika 2.4.: Tipovi visokih učilišta s obzirom na prihodovnu strukturu</i>	18
<i>Slika 2.5.: Prijedlog rasporeda perspektiva i osnovne strukture ciljeva za visoka učilišta</i>	30
<i>Slika 2.6.: Genetička definicija informacijskog sustava visokog učilišta u užem smislu</i>	34
<i>Slika 2.7.: Proširenje genetičke definicije informacijskog sustava visokog učilišta u širem smislu</i>	43
<i>Slika 3.1.: Životni ciklus resursa</i>	61
<i>Slika 3.2.: Analiza životnog ciklusa privremenog entiteta Student</i>	63
<i>Slika 3.3.: Analiza životnog ciklusa stalnog entiteta Nastavnik</i>	64
<i>Slika 3.4.: Analiza životnog ciklusa stalnog entiteta Znanstvenik</i>	65
<i>Slika 3.5.: Analiza životnog ciklusa stalnog entiteta Stručnjak</i>	66
<i>Slika 3.6.: Analiza životnog ciklusa ključnog resursa Nastavni plan i program</i>	67
<i>Slika 3.7.: Analiza životnog ciklusa ključnog resursa Predmet</i>	68
<i>Slika 3.8.: Analiza životnog ciklusa obnavljajućeg resursa Novo temeljno znanje</i>	69
<i>Slika 3.9.: Analiza životnog ciklusa obnavljajućeg resursa Novo primijenjeno znanje</i>	70
<i>Slika 3.10.: Analiza životnog ciklusa ključnog resursa Tehnička infrastruktura i oprema</i>	70
<i>Slika 3.11.: Analiza životnog ciklusa ključnog resursa Novac</i>	71
<i>Slika 3.12.: Osnovni prikaz Porterovnog lanca vrijednosti</i>	72
<i>Slika 3.13.: Rezultati razvrstavanja poslovnih i akademskih procesa visokih učilišta u Porterov lanac vrijednosti</i>	74
<i>Slika 3.14.: Značaj poslovnih i akademskih procesa prema BCG matrici procesa VU</i>	77
<i>Slika 3.15.: Pregledni model procesa visokog učilišta</i>	83
<i>Slika 3.16.: Model procesa vezanih uz upravljanje nastavnim planom i programom</i>	85
<i>Slika 3.17.: Model procesa vezanih uz upis studija</i>	87
<i>Slika 3.18.: Model procesa vezanih uz upis kolegija</i>	89
<i>Slika 3.19.: Model procesa vezanih uz izvođenje nastave</i>	91
<i>Slika 3.20.: Model procesa vezanih uz vođenje završnih radova</i>	93
<i>Slika 3.21.: Model procesa vezanih uz izdavanje diploma</i>	94
<i>Slika 3.22.: Model procesa vezanih uz rješavanje studentskih zahtjeva</i>	96
<i>Slika 3.23.: Model procesa vezanih uz upravljanje akademskim aktivnostima</i>	98
<i>Slika 3.24.: Model procesa vezanih uz rad na znanstveno istraživačkim projektima</i>	100
<i>Slika 3.25.: Model procesa vezanih uz rad na stručnim i komercijalnim projektima</i>	102
<i>Slika 3.26.: Model procesa vezanih uz opskrbu zajedničkim resursima</i>	104
<i>Slika 3.27.: Model procesa vezanih uz upravljanje financijama</i>	106
<i>Slika 3.28.: Model procesa vezanih uz upravljanje poslovanjem</i>	108
<i>Slika 4.1.: Model procesa visokog učilišta Charles Sturt university</i>	112

<i>Slika 4.2.: Mapa procesa visokog učilišta Glendale Community College</i>	113
<i>Slika 4.3.: Model CRM procesa Sveučilišta u Nottinghamu (verzija za instituciju klase B)</i>	114
<i>Slika 4.4.: Model procesa Odabir predmeta</i>	115
<i>Slika 4.5.: Dijagram dekompozicije akademskih procesa prema studentima</i>	115
<i>Slika 4.6. Model procesa za znanstvene projekte visokog učilišta Oxford Brookes</i>	116
<i>Slika 4.7.: Grupe procesa visokog učilišta Sheffield Hallam (Sheffield Hallam High Level Process Model)</i>	117
<i>Slika 4.8.: Pregled procesa visokog učilišta Sheffield Hallam (Sheffield Hallam University Process Model v6)</i>	118
<i>Slika 4.9.: Dekompozicija modula i aplikacija za visoko obrazovanje u alatu Solution Composer</i>	120
<i>Slika 4.10.: Dekompozicija modula i aplikacija za istraživanje u alatu Solution Composer</i>	121
<i>Slika 4.11.: Model procesa za proces Upis na studijski program</i>	122
<i>Slika 4.12.: Prikaz modula ERP sustava proizvođača Oracle</i>	123
<i>Slika 4.13.: Struktura aplikacijskih servisa ERP sustava visokog učilišta prema Li et.al.[52]</i>	124
<i>Slika 4.14.: Model procesa upisa na visoko učilište prema Li et.al.</i>	125
<i>Slika 4.15. Kriteriji za opis referentnih modela</i>	129
<i>Slika 4.16.: Svojstva modela poslovnih i akademskih procesa visokih učilišta</i>	129
<i>Slika 6.1.: Prijedlog modela podataka ERP sustava visokog učilišta</i>	152
<i>Slika 6.2.: Matrica izvedivih pristupa promjenama poslovnih procesa i prilagodbe modula</i>	160
<i>Slika 7.1.: Model osnovnih koncepata ERP sustava za visoka učilišta</i>	166
<i>Slika 7.2.: Model osnovnih koncepata ERP sustava proizvodnog poduzeća</i>	167
<i>Slika 7.3.: Pojednostavljeni grafički prikaz postupka utvrđivanja strukturne sličnosti podatkovnih modela</i>	174
<i>Slika 7.4.: Grafički prikaz faza i koraka postupka određivanja strukturne sličnosti istovrsnih grafičkih modela</i>	176
<i>Slika 7.5.: Podgraf prvog početnog grafa izvedenog iz modela podataka visokog učilišta</i>	202
<i>Slika 7.6.: Podgraf drugog početnog grafa izvedenog iz modela podataka proizvodnog poduzeća</i>	202
<i>Slika 7.7.: Zajednički podgraf modela podataka</i>	203
<i>Slika 7.8.: Model podataka semantički i strukturno sličnih objekata izveden iz zajedničkog podgrafa</i>	204
<i>Slika 8.1.: Razine interoperabilnosti prema EIFu</i>	215
<i>Slika 8.2.: Okvir za pozicioniranje očekivanja i mogućnosti ERP sustava</i>	217
<i>Slika 8.3.: Model složenog multifunkcionalnog procesa Napredovati u zvanju</i>	222
<i>Slika 8.4.: Arhitektura ERP sustava visokih učilišta s popisom funkcionalnosti i vezama prema drugim informacijskim podsustavima</i>	225

POPIS TABLICA

<i>Tablica 2.1.: Temelji upravljanja prema strateškom profilu visokog učilišta</i>	19
<i>Tablica 2.2.: Popis i opis ključnih resursa visokih učilišta</i>	25
<i>Tablica 2.3.: Popis i opis sadržaja veza objekata modela</i>	35
<i>Tablica 2.4.: Popis i opis sadržaja veza objekata proširenog modela</i>	44
<i>Tablica 3.1.: Popis poslovnih i akademskih procesa visokih učilišta</i>	51
<i>Tablica 3.2.: Grupiranje poslovnih i akademskih procesa visokih učilišta s obzirom na značaj u upravljanju resursima poslovanja</i>	58
<i>Tablica 3.3.: Opis značenja simbola korištenih u modelu procesa</i>	79
<i>Tablica 4.1.: Kriteriji usporedbe modela procesa</i>	126
<i>Tablica 4.2.: Usporedna analiza modela procesa</i>	127
<i>Tablica 5.1.: Klasifikacija poslovnih operacija za potrebe klasifikacije ERP sustava</i>	135
<i>Tablica 5.2.: Taksonomija pristupa ERP implementacije</i>	137
<i>Tablica 5.3.: Koraci metodike Dynamics Sure Step</i>	139
<i>Tablica 5.4.: Koraci metodike ASAP</i>	140
<i>Tablica 5.5.: Kratki pregled metodike SPIS – koraci i metode</i>	141
<i>Tablica 5.6.: Faze i koraci generičkog modela razvoja ERP-a</i>	143
<i>Tablica 6.1. Matrica veza procesa i klasa podataka visokih učilišta</i>	147
<i>Tablica 6.2.: Popis tipova modula, proizvođača i nedavnih klijenata implementacije ERP sustava u visokim učilištima u SAD</i>	155
<i>Tablica 6.3.: Informacijski podsustavi visokih učilišta i moduli ERP sustava</i>	158
<i>Tablica 7.1.: Postupci određivanja semantičke sličnosti</i>	169
<i>Tablica 7.2.: Parovi semantički sličnih objekata podatkovnih modela</i>	170
<i>Tablica 7.3.: Faze i koraci postupka određivanja strukturne sličnosti grafičkih modela</i>	177
<i>Tablica 7.4.: Popis veza objekata podatkovnog modela za visoka učilišta</i>	181
<i>Tablica 7.5.: Popis veza objekata podatkovnog modela za proizvodna poduzeća</i>	182
<i>Tablica 7.6.: Katalog entiteta modela podataka podatkovnog modela za visoka učilišta</i>	184
<i>Tablica 7.7.: Katalog entiteta modela podataka podatkovnog modela za proizvodna poduzeća</i>	185
<i>Tablica 7.8.: Moguće vrsta veza entiteta</i>	186
<i>Tablica 7.9. Popis veza objekata podatkovnog modela za visoka učilišta sa zapisom lukova grafa $[[x,y],z]$</i>	187
<i>Tablica 7.10.: Popis veza objekata podatkovnog modela za proizvodna poduzeća sa zapisom lukova grafa $[[x,y],z]$</i>	189
<i>Tablica 7.11.: Odabir semantički sličnih entiteta, njihove oznake i novi položaj u matrici susjedstva</i>	191
<i>Tablica 7.12.: Podaci iz „priprema.xls“ za datoteku „usporedba.wxm“</i>	192
<i>Tablica 7.13.: Srodnost entiteta u početnim modelima i zajedničkom modelu</i>	206
<i>Tablica 8.1. Razine konceptualne interoperabilnosti prema Wang, Tolk, Wang</i>	214

POPIS KRATICA

<i>ASAP</i>	<i>Accelerated SAP</i>
<i>BPMN</i>	<i>Business Process Model and Notation</i>
<i>CFO</i>	<i>Chief financial Officer</i>
<i>CIO</i>	<i>Chief Information Officer</i>
<i>ECAR</i>	<i>Educause Centar for Applied Research</i>
<i>EIF</i>	<i>European Interoperability Framework</i>
<i>ERA</i>	<i>Entity-Relationship-Attribute</i>
<i>ERP</i>	<i>Enterprise Resource Planning</i>
<i>EUA</i>	<i>European University Association</i>
<i>FEA</i>	<i>Federal Enterprise Architecture</i>
<i>HEFCE</i>	<i>Higher Education Funding Council for England</i>
<i>HERDC</i>	<i>Higher education and Research Data Collection</i>
<i>ICT</i>	<i>Information and Communication Technology</i>
<i>IDC</i>	<i>International Data Corporation</i>
<i>IDEF</i>	<i>Integrated Definition metode</i>
<i>IPISVU</i>	<i>Integrirani poslovni informacijski sustav visokih učilišta</i>
<i>IS</i>	<i>Informacijski sustav</i>
<i>ISVU</i>	<i>Informacijski sustav visokih učilišta</i>
<i>JISC</i>	<i>Joint Information Systems Committee</i>
<i>SPIS</i>	<i>Strateško planiranje informacijskih sustava</i>
<i>TOGAF</i>	<i>The Open Group Architecture Framework</i>
<i>UML</i>	<i>Unified Modeling Language</i>
<i>VU</i>	<i>Visoko učilište</i>

1. Uvod

Europska visoka učilišta se suočavaju sa značajnim izazovima. Promjene pokrenute bolonjskom deklaracijom, europske integracijske inicijative i programi, tehnološki zahtjevi tržišta motivirani očekivanjima, promjene modela financiranja, samo su neki od izazova koji od visokih učilišta zahtijevaju prilagodbu na drukčije uvjete „poslovanja“. Visoka učilišta su vjerojatno ostala posljednji bastioni autonomije jer kao „autonomne institucije u društvu imaju pravo na odabir svojih članova, komercijalno neovisno postavljanje ciljeva i funkcioniranje po vlastitim pravilima“ [75].

Funkcioniranje visokih učilišta podrazumijeva, s jedne strane zadržavanje ovakve uloge autonomnog altruiste, dok s druge strane podrazumijeva i ulogu predvodnika u znanstvenim, tehničkim i tehnološkim postignućima. Upravo ovaj antagonizam zahtijeva i motivira razmatranje visokih učilišta i njihovih procesa kojima ostvaruju svoju ulogu s dva aspekta: (1) akademski aspekt, koji ukazuje na to da su visoka učilišta organizacije sa specifičnim ciljevima i načinima postizanja tih ciljeva, te na taj način visoka učilišta izdvaja kao specifične organizacije sa jedinstvenim procesima i (2) poslovni aspekt, koji podrazumijeva da se planiranje i upravljanje resursima visokih učilišta mora odvijati u skladu s tržišnim i ekonomskim načelima upravljanja, a što za ujedno znači da se neki procesi visokih učilišta odvijaju na sličan način kao i u većini poslovnih organizacija. Budući da je nezamislivo razmatrati poslovanje ijedne institucije, pa tako i visokih učilišta, bez odgovarajuće potpore informacijskim i komunikacijskim tehnologijama, potrebno je razmatrati procese visokih učilišta i informacijske sustave koji podržavaju te procese. Postavlja se pitanje jesu li visoka učilišta specifične organizacije koje zahtijevaju specifičan informacijski sustav za potporu njihovim poslovnim procesima? Do odgovora na to pitanje je dug put, a na tom putu treba analizirati oblike organizacije i upravljanja resursima visokih učilišta, strukturu sustava i okruženja u kojem visoka učilišta djeluju, identificirati temeljne poslovne procese kojima se ostvaruju osnovne poslovne djelatnosti ovih institucija te istražiti postojeća aplikativna rješenja namijenjena potpori tim procesima.

1.1. Predmeti i objekti istraživanja

U radu će se istražiti čimbenici koji utječu na upravljanje resursima visokih učilišta kao što su modeli financiranja djelatnosti, razlike poslovnog i javnog sektora u upravljanju resursima, specifičnosti visokih učilišta u RH, organizacijski ustroj i okruženje, te drugi čimbenici. Modelirati će se procesi visokih učilišta s naglaskom na integraciji poslovnih i akademskih aspekata upravljanja resursima visokih učilišta. Istražiti će se postojeći referentni modeli koji su izvedeni iz najbolje prakse primjene ERP sustava na raznim sveučilištima u svijetu. Analizirati će se primjenjivost postojećih modela u domaćem okruženju. U tu svrhu će biti napravljen **referentni model procesa planiranja i upravljanja resursima** na visokim učilištima u RH. Zatim će se analizirati usklađenost tog modela s najboljom svjetskom praksom, važećom zakonskom regulativom, te smjernicama i dokumentima EU.

Osnovni koncepti ERP sustava, prvotno namijenjeni profitno orijentiranoj proizvodnji, primjenjuju se i u sustavima planiranja i upravljanja resursima visokih učilišta. Međutim, specifični procesi i organizacija koji određuju sustav planiranja i upravljanja resursima visokih učilišta ukazuju na to da ERP sustavi visokih učilišta imaju i vlastite jedinstvene koncepte koji nisu prisutni u drugim ERP sustavima. To znači da se sustavi planiranja i upravljanja resursima visokim učilištima ne mogu promatrati kao podvrsta već postojećih ERP sustava, već da su u ontološkom smislu posebna klasa sustava planiranja i upravljanja resursima, te ih kao takve valja i posebno istraživati. Stoga je nužno analizirati strukturnu i semantičku sličnost osnovnih koncepata sustava planiranja i upravljanja resursima u različitim područjima primjene, te identificirati jedinstvene koncepte ERP sustava visokih učilišta, a sve kako bi istražilo jesu li sustavi planiranja i upravljanja resursima visokih učilišta posebna klasa ERP sustava.

Značajan čimbenik uspješnog sustava planiranja i upravljanja resursima je mogućnost suradnje i integracije s drugim informacijskim sustavima. U tom kontekstu će se istražiti **razine i modeli interoperabilnosti ERP sustava visokih učilišta s već implementiranim informacijskim sustavima** visokih učilišta. S obzirom na definiranu minimalnu razinu podatkovne interoperabilnosti predložiti će se referentni model podataka ERP sustava visokih učilišta i sučelja s drugim odabranim informacijskim podsustavima. Definirati će se integracijska sučelja za podatkovnu, procesnu i tehničku

interoperabilnost sustava planiranja i upravljanja resursima visokih učilišta prema drugim postojećim informacijskim podsustavima.

1.2. Pregled dosadašnjih istraživanja i istraživačkih problema

Esteves i Bohorquez [23] su istraživali utjecaj organizacijskog konteksta na sustav planiranja i upravljanja resursima visokih učilišta, te publikacije vezane uz ERP sustave. S obzirom na postojeće publikacije, Esteves između ostalog ističe sljedeće teme za istraživanje: kompleksnost ERP sustava, tehnološka integracija, povezivanje ERP sustava i modela procesa [25], način na koji proizvođači ERP sustava definiraju modele najbolje prakse i kako su ti modeli primijenjeni u ERP sustavima [24].

Paula King je istraživala očekivanja i učinke ERP sustava za visoka učilišta, a u istraživanju je prikupljeno 481 anketa. Iako je upitna reprezentativnost uzorka istraživanja, prikupljeni podaci su indikativni po pitanju modula koji su implementirani [50].

Monk, Wagner [59] i Pollock, Cornford [74] istražuju posebnosti visokih učilišta koje utječu na uspjeh primjene sustava planiranja i upravljanja resursima na visokim učilištima: tradicionalni oblici organizacije, autonomnost u radu visokih učilišta te s druge strane potreba za kontrolom proračuna, upravljanje troškovima, centralizirana administracija, ažurnost informacija u stvarnom vremenu. Pollock i Cornford [74] navode kako se unatoč primjeni modela najbolje prakse neki poslovi i dalje odvijaju na tradicionalan način. Prema Pollocku [75] mnoga sveučilišta se zbog smanjenja troškova administracije okreću prema novim organizacijskim filozofijama kao što je preuzimanje odgovornosti studenata za vlastite podatke (engl. „self-service student“).

Erica Wagner istražuje ulogu sustava planiranja i upravljanja resursima u modernizaciji akademske administracije te sa Sue Newell problematizira primjenu modela najbolje prakse u visokim učilištima. Autorice navode primjer razvoja referentnog modela najbolje prakse kojeg su razvili proizvođači ERP sustav i grupa sveučilišta (Ivy-Vision grupa) koji još uvijek nije u potpunosti implementiran te se Ivy grupa još uvijek bori sa promjenom organizacije i reinženjeringom procesa [94]. Da je reinženjering poslovnih

procesa važan čimbenik uspjeha implementacije ERP sustava tvrdi i Rabaa'i [79], a potvrđuju i Marnewick i Labuschagne [55].

Kod analize referentnih modela podataka i procesa treba uzeti u obzir i smjernice ENQA [21], te australski model HERDC (*engl. Higher education and Research Data Collection*), koji je zamišljen kao okvir za uređivanje podatkovne i infrastrukture sveučilišta [3]. Rosemann [80] istražuje referentne modele i formalne tehnike za nadogradnju i konfiguraciju referentnih modela, dok se Mendling, van der Aalst, et al. bave sintaksnom i semantičkom verifikacijom referentnih modela i upozoravaju na greške u modelima procesa [56].

Autor Yakovlev [97] ističe važnost fleksibilnosti alata i učinkovitog upravljanja podacima te ističe potrebu za interoperabilnošću informacijskih sustava.

Dosadašnja istraživanja nisu bila usmjerena na analizu procesa visokih učilišta prije primjene referentnih modela najbolje prakse, analizu odstupanja u pokrivenosti procesa ERP modulima, te mogućnosti tehničke, semantičke i procesne interoperabilnosti ERP alata i drugih informacijskih sustava. S obzirom na to da je tema rada na tragu istraživačkih tema koje su navedene u pregledanoj literaturi, rad će se dobro uklopiti u dosadašnja istraživanja.

Dosadašnjim istraživanjem identificirani su sljedeći istraživački problemi:

1. Istražiti i odrediti modele i načine financiranja i njihov utjecaj na upravljanje resursima.
2. Istražiti razliku poslovnog i javnog sektora te kako se to odražava na upravljanje resursima. Posebno treba razmotriti poslovni i akademski aspekt upravljanja resursima visokih učilišta.
3. Istražiti eventualne specifičnosti sustava planiranja i upravljanja resursima visokih učilišta u RH.
4. Nedostupnost i/ili nepostojanje cjelovitog referentnog modela procesa visokih učilišta, dosadašnja istraživanja i modeli su usmjereni na pojedinačne procese ili proizvoljno grupirane procese studentske administracije, upravljanja kadrovima i upravljanja financijama visokih učilišta.
5. Provesti klasifikaciju i sistematizaciju ERP sustava.

6. Usporediti standardne funkcionalnosti klasičnih ERP alata i specifične funkcionalnosti ERP sustava za visoka učilišta.
7. Definirati uvjete izgradnje ERP sustava poštujući načelo interoperabilnosti.
8. Istražiti metodologiju izgradnje ERP sustava.

1.3. Hipoteze i očekivani znanstveni doprinos

Na osnovi opisanog problema i predmeta istraživanja, u ovom radu su postavljene sljedeće hipoteze:

H1. Sustavi planiranja i upravljanja resursima visokih učilišta se strukturno i semantički temelje na osnovnim konceptima ERP sustava, ali istovremeno imaju i vlastite koncepte koji ih u ontološkom smislu čine posebnom klasom takvih sustava.

H2. Moguće je napraviti referentni model planiranja i upravljanja resursima koji je specifičan za visoka učilišta, s naglaskom na znanstvenoistraživačku i nastavnu komponentu.

H1 će se testirati na način da će se najprije izraditi podatkovni modeli osnovnih koncepata ERP sustava za visoka učilišta i druge djelatnosti, zatim definirati postupak određivanja semantičke i strukturne sličnosti tih koncepata, te na kraju primijeniti predložene metode analize na podatkovnim modelima. Dobivene spoznaje će ili dokazati ili opovrgnuti hipotezu H1.

H2 će se dokazati izradom modela procesa visokih učilišta i analizom odstupanja tog modela od ostalih javno dostupnih referentnih modela procesa visokih učilišta.

U radu će se primjenom znanstvenih metoda razmotriti procesna i podatkovna komponenta sustava planiranja i upravljanja resursima visokih učilišta s poslovnog i akademskog aspekta. Stoga se može zaključiti da očekivani znanstveni doprinos ima sljedeće komponente:

1. Određivanje primjenjivosti osnovnih koncepata i strukture ERP sustava u specifičnom području planiranja i upravljanja resursima visokih učilišta.

2. Izrada referentnog modela procesa planiranja i upravljanja resursima visokih učilišta s naglaskom na integraciju poslovnih i akademskih aspekata.
3. Definiranje integracijskog procesnog i podatkovnog sučelja i određivanje uvjeta interoperabilnosti ERP sustava visokih učilišta i drugih informacijskih podsustava.

2. Utjecaj organizacijskih čimbenika i okruženja na sustav planiranja i upravljanja resursima visokih učilišta

U ovom poglavlju se najprije daje pregled osnovnih pojmova vezanih uz planiranje i upravljanje resursima. Zatim se analiziraju oblici organizacije i upravljanje visokih učilišta kako bi se utvrdilo utječu li ovi faktori na način planiranja i upravljanja resursima visokih učilišta. Nakon toga se pojmovno definiraju osnovni resursi visokih učilišta. U nastavku se analiziraju modeli i načini financiranja visokih učilišta kako bi se ocijenilo da li model financiranja utječe na način planiranja i upravljanja financijskim i drugim resursima visokih učilišta. Na kraju poglavlja se analizira struktura veza sustava i okruženja visokih učilišta te se daje genetička definicija informacijskog sustava visokog učilišta prema organizacijskim čimbenicima.

2.1. Oblici organizacije i upravljanja visokih učilišta

Na početku razmatranja treba definirati osnovne pojmove vezane uz „visoko učilište“. Zakonom o visokim učilištima [64] su pravno definirani sljedeći osnovni pojmovi:

- **„Visoko učilište** – svaka ustanova visoke naobrazbe ovlaštena za ustroj i izvedbu studija te znanstvenog, visokostručnog ili umjetničkog rada,
- **Sveučilište** – visoko učilište koje ustrojava i izvodi sveučilišne studije, znanstveni i visokostručni rad i razvija vrhunsko umjetničko i tehnološko stvaralaštvo,
- **Veleučilište** – visoko učilište koje ustrojava i izvodi stručne studije i razvija visokostručni i umjetnički, a iznimno i znanstveni rad,
- **Fakultet** – visoko učilište u sastavu sveučilišta koje ustrojava i izvodi sveučilišne studije, znanstveni i visokostručni rad u jednom ili više znanstvenih i obrazovnih područja,
- **Umjetnička akademija** – visoko učilište u sastavu sveučilišta koje ustrojava i izvodi sveučilišne studije, znanstveni i umjetnički rad u jednom ili više znanstvenih, obrazovnih i umjetničkih područja,
- **Visoka škola** – visoko učilište (stručno ili umjetničko) u sastavu ili izvan veleučilišta koje ustrojava i izvodi stručne studije i visokostručni rad u jednom ili više obrazovnih područja,

- **Odjel** – ustrojbeni jedinica sveučilišta, koja sudjeluje u izvedbi sveučilišnih studija te ustrojava i izvodi znanstveni, nastavni i visokostručni rad u jednom znanstvenom polju, u odjelu su u pravilu svi nastavnici i suradnici sveučilišta iz toga znanstvenog polja,
- **Veleučilišni odjel** – ustrojbeni jedinica veleučilišta, koja sudjeluje u izvedbi stručnih studija te ustrojava i izvodi nastavni i visokostručni rad u jednom području,
- **Centar za znanstveni ili visokostručni rad** – pravna osoba ili ustrojbeni jedinica visokog učilišta koja ustrojava i izvodi znanstveni, visokostručni ili nastavni rad, odnosno usklađuje njegovu izvedbu između visokih učilišta,
- **Studij** – program kojeg ustrojava i izvodi visoko učilište, a čijim završavanjem student stječe visoku naobrazbu i odgovarajući stručni naziv ili akademski stupanj,
- **Sveučilišni studij** – studij koji se izvodi bilo na razini sveučilišta ili visokih učilišta u sastavu sveučilišta, a stupnjem znanja koja se na njemu stječu omogućuje, uz obavljanje određenog zanimanja i bavljenje znanstvenim ili umjetničkim radom,
- **Stručni studij** – svaki studij koji se izvodi na razini veleučilišta, visokih škola u sastavu ili izvan veleučilišta, a stupnjem stručnih znanja i umijeća koja se na njemu stječu, omogućuje uspješno bavljenje i unapređivanje nekog zvanja (struke),
- **Student** – osoba koja redovito ili izvanredno studira na dodiplomskom¹ ili poslijediplomskom studiju,
- **Nastavnik** – osoba koja izvodi nastavu i bavi se znanstvenim, stručnim ili umjetničkim radom na visokom učilištu.“

Prethodno navedene definicije pojmova su prihvatljive za potrebe izrade ovog rada i nisu kontradiktorne sa pojmovnim shvaćanjem visokog učilišta koji će se u ovom radu koristiti. Ipak valja na početku naglasiti da će se u sklopu rada povremeno razlikovati dva oblika visokih učilišta, s obzirom na njihov organizacijski ustroj:

1. **Visoko učilište u užem smislu** – visoko učilište s pravnom osobnošću koje u svom ustroju nema pravnih subjekata kao sastavnica te institucije. To može biti fakultet s pravnom osobnošću (kakvi su gotovo svi fakulteti u RH, npr. Fakultet organizacije i informatike), ali i sveučilište koje unutar svog ustroja ne obuhvaća druge sastavne jedinice (sastavnice) koje istovremeno imaju status pravne osobe

¹ Dodiplomski studij je po Bolonjskom sustavu zamijenjen preddiplomskim i diplomskim studijem.

(npr. u RH Sveučilište u Dubrovniku, neka europska i američka sveučilišta). Svako visoko učilište ove grupe ima prava i obveze koje proizlaze iz njihova pravnog statusa: samostalnost u izvođenju poslova, financijska odgovornost, vlastite strukture odlučivanja i upravljanja i drugo.

2. **Visoko učilište u širem smislu** – visokoobrazovna institucija koja je ustrojena od više sastavnica sa pravnom osobnošću. Primjer institucije visokog učilišta u širem smislu je Sveučilište u Zagrebu kao ustrojstveno nadređena institucija Fakulteta organizacije i informatike.

Ako nije izričito navedeno drugačije, onda će se pod visokim učilištem smatrati visoko učilište u užem smislu.

Složeni organizacijski odnosi visokoobrazovnih institucija u užem i širem smislu su bitni za razmatranje načina planiranja i upravljanja resursima visokih učilišta. S jedne strane postoje visoka učilišta u užem smislu (npr. fakulteti) koja su pravne osobe, te s obzirom na taj status imaju određena prava i obveze. S druge strane ta učilišta (fakulteti) mogu biti sastavni dio neke druge institucije (Sveučilišta) te u skladu s tim odnosom imaju i određena prava i obveze prema nadređenoj instituciji, ali i nadređena institucija prema svojim sastavnicama. Fakulteti povremeno zajednički nastupaju prema okruženju u sklopu jedinstvene visokoobrazovne institucije, odnosno kao Sveučilište, što je onda usmjereno stremljenju ostvarivanja zajedničkih ciljeva, a da pritom ne budu zanemarene aktivnosti ostvarenja vlastitih ciljeva. Tipičan primjer ovog dualizma je zajedničko nastupanje fakulteta kao sastavnica Sveučilišta prema nadležnom Ministarstvu radi planiranja i rezervacije proračunskih sredstava za financiranje osnovnih djelatnosti koje se provode na Sveučilištu i s druge strane samostalno nastupanje prema studentima radi pridobivanja najboljih učenika, ili na tržištu radi ostvarivanja vlastitih prihoda.

Visoka učilišta se često kolokvijalno dijele na privatna i državna (*engl. Public university, State University*). Problematika ove osnovne podjele nastaje kada trebamo odrediti kriterij po kojem visoka učilišta razlikujemo na državna i privatna [72]. U radu će se visoka učilišta klasificirati razlikovati kao privatna i državna prema sljedećim kriterijima:

- vlasnička struktura ili osnivač;
- glavni izvor financiranja nastavne i znanstveno istraživačke djelatnosti;

- ključni korisnici (naglašena društvena korist ili tržišna potreba);
- pravo dostupnosti, odnosno otvorenost prema javnosti.

U radu ćemo pod državnim visokim učilištima smatrati visoka učilišta čiji je osnivač država, koje imaju izričito naglašenu društvenu ulogu, čije se nastavne i znanstveno istraživačke djelatnosti financiraju iz državnog proračuna, koja su otvorena prema javnosti te studentima mogu biti dostupna uvjetno rečeno besplatno. Pod privatnim visokim učilištima ćemo smatrati visoka učilišta čiji osnivač nije država, financiraju se iz raznih izvora (donacija, zaklada, od strane privatnih poduzeća isl.), mogu imati ograničenja otvorenosti prema javnosti (ako tako izaberu) te mogu zahtijevati proizvoljan iznos naknade za pohađanje studijskog programa (uključujući i opciju uvjetno rečeno besplatnog studiranja ili punog plaćanja).

S obzirom na značaj visokog obrazovanja za društvo, podjela na privatna i državna učilišta ne smije biti odrednica kvalitete izlaznog proizvoda ili usluge visokog učilišta, kvalitete procesa ili kvalitete upravljanja visokim učilištem. Stoga klasifikacija visokih učilišta na privatna i državna visoka učilišta ne govori ništa o načinu upravljanja visokim učilištem.

Upravljačka tijela visokih učilišta se razlikuju po svojoj strukturi i sastavu. Tako prema strukturi visoko učilište može imati upravljačko tijelo koje je sastavljeno od izabranih predstavnika nastavnog i znanstvenog kadra i/ili upravljačko tijelo profesionalnih menadžera. Područje i predmet upravljanja mogu biti ograničeni na samo akademski aspekt poslovanja, samo poslovni dio poslovanja ili mogu obuhvaćati oba područja. Prema OECD izvješću [67], mogu se razlikovati sljedeća područja i funkcija upravljanja:


- upravljanje organizacijom (*engl. Governance*),
- upravljanje i vođenje poslovanja (*engl. Management*)
- upravljanje i vođenje poslova vezanih uz akademsku ulogu visokog učilišta. (*engl. Academic affairs*).

Prema strukturi upravljačka tijela mogu biti definirana i strukturirana hijerarhijski, projektno, ili na neki drugi način. Prema Eurydice izvješću [29], upravljačka tijela visokih učilišta djeluju na 4 razine: na razini upravljanja institucijom (npr. rektor, predsjednik, direktor, dekan, *engl. Dean, Rector, President, Director, Provost*), na razini

upravljanja akademskim aspektom poslovanja (npr. akademsko vijeće, fakultetsko vijeće, *engl. Academic Board, Academic Council, Conference, Senate, Scietific Council*), na razini donošenja odluka (npr. akademski senat, upravljačko vijeće, *engl. Educational Management Council, Governing Board, General Assembly*) i na savjetodavnoj nadzornoj razini (npr. socijalno vijeće, upravljačko vijeće, administrativno vijeće (*engl. Social Council, Governing Board*)).

Visoka učilišta u širem smislu mogu imati i vlastita upravljačka tijela koja su u pravilu u nekom smislu nadređena sastavnici, čime komunikacijski tijekovi, raspodjela odgovornosti i područje upravljanja postaju kompleksne mreže.


Europska udruga sveučilišta (*engl. European University Association*, kraće EUA) je provela istraživanje o stanju sveučilišta nakon uvođenja „Bolonjske deklaracije“ te u izvješću Trends 2010: a decade of change in European Higher Education [28] navela osnovne rezultate istraživanja. Od danih rezultata su u kontekstu ovog rada izrazito zanimljiva dva pitanja koja se odnose na promjene u upravljanju visokim učilištima. Prvo pitanje se odnosilo na važnost oblika promjene za visoko učilište u posljednjih 10 godina, a ispitanici su kao najvažnijih pet promjena odabrali unapređenje internih procesa kvalitete (60% ispitanika), unapređenje suradnje s drugim visokim učilištima (odabralo 53% ispitanika), više autonomije (43%), unapređenje suradnje s gospodarstvom (važno je za 42% ispitanika) te diversifikacija izvora financiranja (važno za 41% ispitanika). Slika 2.1. daje grafički prikaz zastupljenosti svih odgovora na postavljeno pitanje.



Slika 2.1.: Grafički prikaz učestalosti odgovora na pitanje važnosti oblika promjene za visoko učilište u posljednjih 10 godina²

Drugo pitanje se odnosilo na tri najvažnija napora u promjenama vezanim uz financiranje na vlastitom visokom učilištu. Ispitanici su trebali odabrati tri ponuđena odgovora koja su za njihovu instituciju imala važnost. Kao prvi odabir je 22% ispitanika odabralo povećanje financiranja nastavne djelatnosti, dok je najčešće odabran odgovor povećanje financiranja europskih i međunarodnih istraživanja. Slika 2.2. grafički prikazuje zastupljene odgovore.

² Preuzeto i prevedeno iz dokumenta *Trends 2010: a decade of change in European Higher Education* [28]



Slika 2.2.: Grafički prikaz učestalosti odgovora na pitanje odabira tri najvažnija napora u promjenama vezanim uz financiranje na vlastitom visokom učilištu³

Zaključno možemo reći da je svojstvo autonomije visokih učilišta doprinijelo raznolikosti u oblicima ustrojstva i strukturama upravljanja. Umjesto pokušaja standardizacije organizacijskih oblika, nužno ih je razumjeti i uzeti u obzir činjenicu, da ustroj visokog učilišta i struktura upravljačkih tijela mogu utjecati na planiranje i upravljanje visokim učilištem.

2.2. Financiranje visokih učilišta

Financiranje državnih visokih učilišta se smatra socijalnom stečevinom koja osigurava rast i razvoj društva. Ovakvo sagledavanje uloge visokog obrazovanja je neupitno važno i korisno, ali se postavlja pitanje je li održivo? U Europi je prošlo je puno vremena od kada

³ Preuzeto i prevedeno iz dokumenta *Trends 2010: a decade of change in European Higher Education* [28]

je pohađanje visokog učilišta bila čast, kada je bilo malo visoko obrazovanih u ukupnoj populaciji, kada je malo upisanih studenata odustajalo od studija ili ga zanemarivalo, kada se općenito, socijalno vrlo visoko cijenilo formalno fakultetsko obrazovanje. Iako se u nekim zemljama svijeta i dan danas čine naponi da se ostvari dostupnost visokog obrazovanja svima koji žele studirati, u europskim zemljama je pitanje dostupnosti studija manje važno od nekih drugih pitanja: Tko će to sve platiti? Što smo dobili Bolonjskom deklaracijom? Kolika je cijena školovanja jednog studenta? Sve češće se čuje izraz „Besplatno studiranje“ koji se poistovjećuje s modelima financiranja nastavne djelatnosti prema kojima student uopće ne sudjeluje ili sudjeluje tek manjim iznosom, dok za veći ostatak troškova nije uvijek sasvim jasno tko će ih i kako financirati.

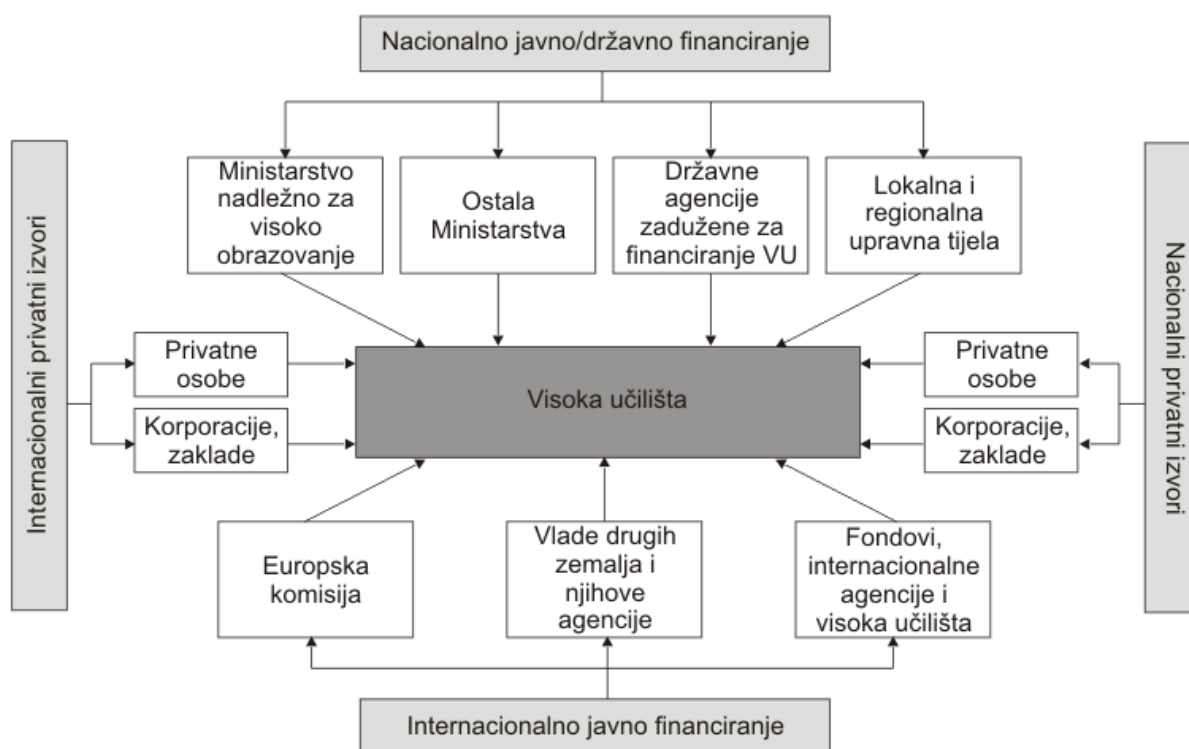
Prema izvoru financiranja razlikujemo privatne izvore financiranja (fondovi, zaklade, participacija građana/studenata kroz školarine, poduzeća), državne izvore financiranja iz fondova, državnog proračuna od strane državnih agencija i tijela uprave i druge. Prema Zakonu o znanstvenoj djelatnosti i visokom obrazovanju [65], visoka učilišta, instituti i druge znanstvene institucije u RH se financiraju iz sljedećih izvora prihoda:

1. sredstava osnivača,
2. državnog proračuna Republike Hrvatske,
3. proračuna županija, gradova i općina,
4. Nacionalne zaklade za znanost, visoko školstvo i tehnološki razvoj RH,
5. vlastitih prihoda ostvarenih na tržištu od školarina, istraživačkih, umjetničkih i stručnih projekata, elaborata, ekspertiza, nakladničke i drugih djelatnosti,
6. sveučilišnih i ostalih zaklada, ostvarene dobiti trgovačkih društava i drugih pravnih osoba,
7. izravnih ulaganja pojedinaca, trgovačkih društava i drugih pravnih osoba,
8. donacija, te
9. ostalih izvora.

Prihodi iz državnog proračuna predstavljaju prilično stabilan izvor financiranja. Prema Hunjaku[37], “glavni pozitivni učinak stabilnog financiranja (osigurane plaće i održavanje infrastrukture) je fleksibilnost u prihvatanju novih ideja i rizičnih projekata. Negativan učinak stabilnog financiranja koji se ne oslanja na mjerenje rezultata izražava se kroz: a) pasivnost u radu akademskog osoblja, vodi smanjenju broja čistih istraživanja

(*engl. pure research*) i porast primijenjenih (*engl. applied research*) koja imaju veće izgleda na uspjeh, b) porasta broja publikacija i radova uz smanjenje njihove kvalitete, te c) nemogućnost transformacije rezultata znanstvenih istraživanja i novih znanja u tržišno usmjerene proizvode.“

Na slici 2.3. su prikazani izvori financiranja visokih učilišta prema izvješću EUA o financijskoj održivosti visokih učilišta [27]. Autori teksta razlikuju četiri glavne kategorije izvora financiranja: nacionalni javni izvor, nacionalni privatni izvori, internacionalni javni izvori i internacionalni privatni izvori financiranja. Za svaku od ovih kategorija su dani tipični predstavnici (upravna tijela, privatne osobe, ministarstva, i dr.). Strelice koje povezuju izvore financiranja predstavljaju tok (kanal) kojim putuju financijska sredstva, pri čemu svakim tokom sredstva mogu biti dodijeljena za različite svrhe: financiranje školarina, upisnina, znanstveno istraživačkih projekata, publikacija, konferencija, stručnih projekata, razvoja novih nastavnih programa, znanstveno usavršavanje, primjenu novih tehnologija u nastavnoj djelatnosti, te u druge svrhe.



Slika 2.3.: Izvori financiranja visokih učilišta⁴

⁴ Izrađeno prema: European University Association, Financially Sustainable Universities, Towards Full Costing In European Universities, 2008. [27]

Prema izvješću pod nazivom „Financiranje visokog obrazovanja u Hrvatskoj – slučaj Sveučilišta u Zagrebu“ [19, str. V] „trend komercijalizacije visokog obrazovanja nužno upućuje na potrebu promjene filozofije financiranja visokih učilišta.“ Postoje različiti modeli financiranja visokih učilišta, koji se uglavnom temelje na nekom od četiri vrste pokazatelja [19, str. 13]:

- financiranje prema ulaznim tokovima (engl. ***Input based financing***) je financiranje prema količini ili značaju ulaznih resursa koji se koriste u provedbi procesa ili pokreću izvršenje procesa: upisani studenti, nastavnici, prihodi, imovina, studijski program, predmet, znanstveni projekt, stručni projekt, i drugo;
- financiranje prema rezultatima (engl. ***Output based financing***) je financiranje prema količini ili značaju izlaznih resursa koji su rezultat provedbe procesa: apsolvanti, objavljeni radovi, patent, broj doktoranada u akademskoj godini, broj magistranada u akademskoj godini, i slično;
- financiranje prema procesima (engl. ***Process based financing***) je financiranje pojedinačnih poslova ili provedbe nekog skupa povezanih poslova kojim se ulazni resursi transformiraju u izlazne: istraživanje, seminar, tečaj, predavanje, konzultacije, laboratorijska testiranja, izrada prototipa, kliničko ispitivanje...
- financiranje prema učinku (engl. ***Outcome based financing***) je financiranje prema ostvarenom društvenom utjecaju ili doprinosu: diplomirani studenti, rashodi, dobit, inovacije, prototip proizvoda, transfer znanja u društvo, itd.

Prema Eurydice izvješću o upravljanju europskim visokim učilištima [29], modeli financiranja za izravno financiranje iz državnih izvora su:

1. Određivanje iznosa financijskih sredstava iz državnog proračuna prema planiranom proračunu visokog učilišta;
2. Određivanje iznosa financijskih sredstava iz državnog proračuna prema stvarnim troškovima visokog učilišta iz jednog ili nekoliko prethodnih razdoblja;
3. Određivanje iznosa financijskih sredstava prema formuli;
4. Određivanje iznosa financijskih sredstava prema ugovorenim učincima (engl. *performance contracts*) ostvarenja strateških ciljeva;
5. Određivanje iznosa financijskih sredstava prema ugovorenom broju apsolvenata u znanstvenom području;

6. Određivanje iznosa financijskih sredstava za znanstveno istraživačke projekte putem natječaja.

Kod određivanja iznosa financijskih sredstava prema formuli razlikuju se:

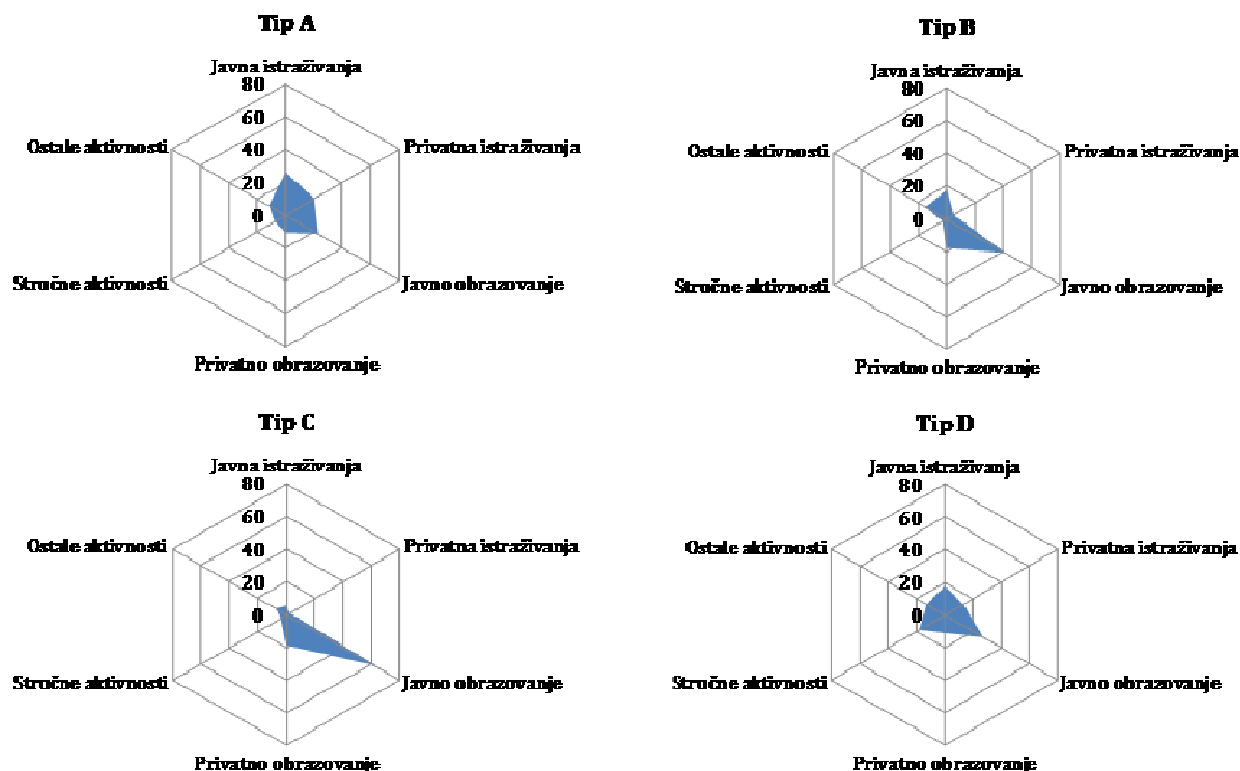
- kriteriji vezani uz ulazne resurse visokog učilišta, kao na primjer:
 - broj upisanih bruceša u prošloj akademskoj godini,
 - broj upisanih studenata u prošloj akademskoj godini,
 - broj upisnih mjesta koja se financiraju iz državnog proračuna,
 - broj javno dostupnih upisnih mjesta na privatnom visokom učilištu;
- kriteriji vezani uz ostvarene učinke strateških ciljeva, kao na primjer:
 - indikatori vezani uz uspjeh studenata,
 - smanjenje operativnih troškova,
 - povećanje kvalifikacija nastavnog osoblja,
 - rezultati vezani uz vrednovanje znanstvenog i/ili stručnog doprinosa institucije,
 - rezultati vezani uz kvalitetu infrastrukture, upravljanja, pružanje usluga i akademsku populaciju.

Prema izvješću engleskog vijeća za financiranje visokih učilišta (*engl. Higher Education Funding Council for England*, skraćeno HEFCE) iz 2010. godine [34] visoka učilišta u Engleskoj se financiraju različitih izvora koji podupiru sljedećih 6 prihodovnih grana:

1. Javna istraživanja – znanstveno-istraživačka djelatnost koja se financira iz nacionalnih javnih financija;
2. Privatna istraživanja – znanstveno-istraživačka djelatnost financirana iz privatnih izvora, komercijalna znanstvena istraživanja i EU projekti;
3. Javno obrazovanje – nastavna djelatnost koja se financira iz nacionalnih javnih financijskih izvora, nacionalno reguliranih školarina;
4. Privatno obrazovanje – programi cjeloživotnog obrazovanja, profesionalna usavršavanja, seminari, tečajevi financirani iz privatnih izvora;
5. Stručne aktivnosti – komercijalne djelatnosti, konzultantske usluge, projekti transfera znanja financirani prema tržišnim uvjetima; te
6. Ostale aktivnosti – druge aktivnosti koje donose prihode (najam, oročenja i sl.).

Ovisno o tome kako su prihodovne grane zastupljene u ukupnim prihodima visokog učilišta HEFCE je prepoznala 4 tipa visokih učilišta (tip A do tip D) koji su grafovima prikazani na slici 2.4.

Slika 2.4.: Tipovi visokih učilišta s obzirom na prihodovnu strukturu⁵



Za svaki tip visokog učilišta prema strukturi prihoda je nadalje prepoznato 5 tipova visokih učilišta sa specifičnim strateškim profilom sa usmjerenošću na znanstveni ili stručni rad ili nastavu. Za tih 5 tipova visokih učilišta u izvješću su naznačeni i opći temelji operativnog upravljanja prema strateškom profilu visokog učilišta (tablica 2.1.). Za visoka učilišta tipa A, čiji se prihodi uglavnom ostvaruju javnim izvorima financiranja znanstveno-istraživačkog rada, su najznačajnije izražene istraživačke aktivnosti, te je njihov strateški profil primarno istraživački (*engl. primary research*); s visokim učilištima tipa B je povezan strateški profil koji se može okarakterizirati kao „nastava temeljena na istraživanju“ (*engl. Research-led teaching*); tip C se povezuje s visokim

⁵ Preuzeto i prevedeno iz dokumenta *Higher Education Funding Council for England Publications: The higher education workforce framework 2010: Overview report*, HEFCE, 2010. [34]

učilištima profiliranim u području formiranja stručnjaka (*engl. Professional formation*); a tip D s visokim učilištima koja značajno doprinose kvaliteti nastave razvojem praktičnih rješenja na temelju istraživačkog rada (*engl. Research-led solutions*). Posljednji strateški profil se odnosi na visoka učilišta koja djeluju u specifičnim znanstvenim područjima (*engl. Specialist institutions*), a koja nisu prepoznata u postojećim tipovima visokih učilišta.

Tablica 2.1.: Temelji upravljanja prema strateškom profilu visokog učilišta⁶

Strateški profil VU	Oblici upravljanja
Prvenstvena orijentacija na istraživački rad	Upravljanje i praćenje učinkovitosti se temelji na rezultatima istraživačkog rada. Ključni kriteriji mjerenja učinkovitosti su kvaliteta i inovacije, a moguća mjera je broj i vrijeme potrebno mladim istraživačima za napredovanje.
Orijentacija na nastavu	Upravljanje i praćenje učinkovitosti se temelji na kombinaciji mjernih jedinica za kvalitetu istraživačkog rada i mjernih jedinica za kvalitete prijenosa teoretskog znanja i praktičnih iskustava tijekom nastave.
Stručna orijentacija	Upravljanje i praćenje učinkovitosti se provodi s ciljem povećanja kvalitete nastave i osiguranja stručne konkurentnosti studenata u odnosu na najbolju svjetsku praksu struke.
Projektно istraživačka orijentacija	Upravljanje visokim učilištem se provodi u skladu s orijentacijom na razvoj sposobnosti visokog učilišta da znanstveno istraživačkim radom generira nova inovativna rješenja u odabranim djelatnostima i znanstvenim područjima. Zaposlenici se uključuju u projekte koji visokom učilištu osiguravaju stabilan izvor financiranja dijela troškova visokog učilišta.
Specijalističke institucije	Upravljanje i praćenje učinkovitosti je usmjereno ka gradnji i očuvanju imidža visokog učilišta kao prepoznatljivog centra izvrsnosti u odabranom području.

Operativno upravljanje visokim učilištem ima za cilj racionalno trošenje prihoda na troškove obavljanja djelatnosti.

Prema Hunjaku [36], troškovi visokog učilišta koji se financiraju iz vlastitih sredstava su:

- plaće i dodaci na plaće zaposlenika i vanjskih suradnika,
- autorski honorari,
- troškovi poslovanja,
- kapitalna izgradnja.

⁶ Higher Education Funding Council for England Publications: The higher education workforce framework 2010: Overview report, HEFCE, 2010. [34]

Prema korisnicima razlikujemo financiranje primarnih djelatnosti visokih učilišta i financiranje studentskog standarda, odnosno financiranje studijskih i životnih troškova vezanih uz studij. Troškovi visokih učilišta i studentskog standarda koji se financiraju iz proračuna su:

- plaće i naknade zaposlenicima,
- materijalni troškovi,
- osnovni troškovi znanstvenog, umjetničkog i stručnog rada,
- troškovi rada službi čijom se djelatnošću osigurava cjelovitost i standard sustava visokog obrazovanja (studentski centri, knjižnice, računski centri),
- stipendije i zajmovi studentima,
- radni i životni standard zaposlenika i studenata, te
- troškovi novčane pripomoći školarinama, razvoju i ulaganju [19].

Prema Baji [4], troškovi studentskog standarda koji se financiraju iz različitih izvora su razni oblici potpore studentima, te se kao takvi mogu smatrati i troškovima visokog obrazovanja u širem smislu:

- Stipendije i slične potpore: namijenjene za školarine ili namijenjene za opće namjene uključujući i troškove života;
- Posebne potpore u gotovini ili robi: subvencije za stanovanje, subvencije za prijevoz (uključujući prijevoz morem i kopnom), subvencije za zdravstvene usluge, nabavu knjiga, za društvene i svrhu rekreacije, subvencije za studiranje u inozemstvu (za školarine i/ili upisnine), ostale subvencije;
- Dječji doplatak vezan uz status studenta;
- Javni i privatni krediti: namijenjeni za školarine, za opće namjene uključujući troškove života, javne subvencije ili državna jamstva za studentske kredite koje pružaju privatne financijske institucije, privatni krediti;
- Porezni odbici i olakšice: porezni odbici i olakšice za školarine, za obitelji za potporu studenta, te ostalo.

Upravljanje većim dijelom prava iz studentskog standarda je u RH povjereno Studentskom centru, u čijoj je nadležnosti i upravljanje infrastrukturom koja je potrebna za realizaciju prava (npr. Studentski domovi).

Prema obračunskim jedinicama razlikujemo: financiranje provedbe studijskih programa, financiranje školarine studenta, financiranje životnih troškova studenata, financiranje znanstveno istraživačkih projekta, financiranje nominalnih troškova plaća i fiksnih troškova, financiranje po aktivnostima (*engl. Activity based costing*) i drugo. Od prethodno nabrojanih obračunskih jedinica je trenutno u fokusu financiranje troškova po aktivnostima.

Prema podacima EUA, visoka učilišta djeluju u izazovnom okruženju koje karakterizira globalizacija tržišta visokih učilišta i rastuća konkurencija. Uz sve veće potrebe tržišta za inovacijama, visoka učilišta su pozvana da sudjeluju na različite načine u razvojnim projektima, što otvara nove mogućnosti financiranja, ali uz povećanje napora u izvedbi i realokaciju dijela postojećih resursa na nove aktivnosti. Primjena novih tehnologija u nastavi i znanstveno-istraživačkom radu zajedno s povećanjem radnih aktivnosti zahtijevaju i veće troškove sudjelovanja visokih učilišta u ovim tokovima. Diversifikacija izvora financiranja otvara i druga pitanja kao što je pitanje mogućnosti planiranja i izvješćivanja o utrošku sredstava prema više različitih izvora financiranja s različitim oblicima praćenja utroška resursa i namjenskih financijskih sredstava. Pokušaj standardizacije upravljanja resursima i ujednačenog načina planiranja, upravljanja i praćenja resursima je bio uvođenje ABC (*engl. activity based costing*) metode upravljanja troškovima. Prema Blocher et.al. [5], ABC sustav se temelji na aktivnostima koje predstavljaju mjesta troškova, odnosno mjesta nastanka i pridruživanja izravnih i neizravnih troškova korištenja resursa. Noreen et.al [66] predlažu uvođenje ABC metode prema modelu koji obuhvaća 4 koraka: (1) odrediti objekte troškova (kao što su usluge, proizvodi, korisnici); (2) definirati aktivnosti za realizaciju objekata; (3) prepoznati i planirati resurse potrebne za izvođenje aktivnosti; te (4) identificirati troškove korištenja resursa. Zbog različitosti računovodstvenih teorija koje se primjenjuju na visokim učilištima u različitim državama i drugih specifičnosti koje utječu na knjigovodstveno praćenje troškova EUA predlaže pojam cjelovitog praćenja troškova (*engl. Full-costing*) koja bi ujedno omogućavala jednoznačnu usporedbu visokoobrazovnih institucija u Europi i šire. Pojam cjelovitog praćenja troškova EUA definira kao sposobnost identifikacije, obračuna svih direktnih i indirektnih troškova po aktivnostima organizacije. Cjelovito praćenje troškova nije samo sebi svrha, već alat koji

treba podržavati upravljanje resursima u učinkovitom obavljanju djelatnosti s ciljem ostvarenja strateških ciljeva organizacije. Primjena cjelovitog praćenja troškova nije jednostavan zadatak, jer cjelovito praćenje troškova zahtijeva određene promjene načina planiranja i upravljanja resursima visokih učilišta, kvalitetnu podatkovnu infrastrukturu u informacijskom sustavu, razgraničavanje indirektnih troškova, te planiranje i provedbu odgovarajućih reaktivnih mjera s obzirom na ostvarene rezultate.

Međunarodni fondovi i zaklade nastoje potaknuti visoka učilišta na uvođenje cjelovitog praćenja troškova tako što uvjetuju oblike i načine izvješćivanja o utrošku namjenskih sredstava za istraživačke projekte prema realiziranim aktivnostima, uzimajući u obzir i direktne i indirektne troškove. S druge strane nacionalni izvori ne financiraju indirektne troškove visokih učilišta u linijama financiranja nastavne i znanstveno-istraživačke djelatnosti, što visoka učilišta trenutno ne motivira na uvođenje cjelovitog praćenja troškova. Visoka učilišta zato prate i izvješćuju o troškovima na više načina, jer ako žele participirati u korištenju financijskih sredstava za projekte iz međunarodnih izvora moraju planirati i upravljati troškovima prema planiranim aktivnostima projekata i izvješćivati o realizaciji prema provedenim aktivnostima projekata sa svim direktnim i indirektnim troškovima, dok se za potrebe izvještavanja prema nacionalnim izvorima financiranja upravljanje troškovima još uvijek izvodi prema nacionalnim računovodstvenim standardima. Promjene načina financiranja visokih učilišta koje se najavljuju novim izmjenama zakona koji uređuju visoko obrazovanje i znanstvenu djelatnost, mogu utjecati na način izvještavanja ako nacionalni izvori financiranja budu uvjetovali drugačije načine izvješćivanja, a visoka učilišta će se tim zahtjevima morati prilagoditi.

2.3. Financiranje visokih učilišta u RH

Financiranje državnih visokih učilišta u RH je definirano Zakonom o proračunu [63], Pravilnikom o proračunskom računovodstvu i računskom planu [61], Pravilnikom o utvrđivanju korisnika proračuna i o vođenju registra korisnika proračuna [62], Pravilnikom o financijskom izvještavanju u proračunskom računovodstvu [60], te posebnim pravilnicima sveučilišta (npr. Pravilnik o osnovama financiranja Sveučilišta u

Zagrebu). Prema Hunjaku [37], „postoji velik broj proračunskih modela financiranja visokih učilišta. Međutim većina modela se može prepoznati kao varijacije osnovna tri proračuna. To su proračuni utemeljeni na: 1. formuli, 2. pokazateljima uspješnosti te 3. izvršenju iz prošlih godina.“ Najčešće se pak koriste kombinacije više različitih modela. Visoka učilišta u RH većim dijelom egzistencijalno ovise o 6 izvora financiranja (sredstvima osnivača, sredstvima iz državnog proračuna Republike Hrvatske, proračuna županija, gradova i općina, Nacionalne zaklade za znanost, visoko školstvo i tehnologijski razvoj Republike Hrvatske, vlastitih prihoda ostvarenih na tržištu od školarina, istraživačkih, umjetničkih i stručnih projekata, elaborata, ekspertiza, nakladničke i drugih djelatnosti, te sveučilišnih i ostalih zaklada, ostvarene dobiti trgovačkih društava i drugih pravnih osoba), jer u RH ne postoji tradicija niti motivi za izravna ulaganja pojedinaca, trgovačkih društava i drugih pravnih osoba, te donacija. Osim nastavne djelatnosti postoje različiti modeli financiranja znanstveno istraživačke i financiranje stručne djelatnosti kroz fondove, iz državnog proračuna, ili npr. iz donacija. I nadležno Ministarstvo znanosti, obrazovanja i športa je prepoznalo problem dugoročne održivosti financiranja znanosti i visokog obrazovanja te je u svom Akcijskom planu za poticanje ulaganja u znanost i istraživanje iz 2008. godine predvidjelo čak jednu mjeru za poticanje donacija kao novog izvora financiranja, koja se svodi na uvođenje poreznih olakšica za ulagače donatore.

Javna visoka učilišta u RH se financiraju iz različitih izvora a značajan dio troškova nastavne djelatnosti se financira iz državnog proračuna. Pritom nadležno Ministarstvo znanosti obrazovanja i športa ima ulogu posrednika prema visokim učilištima, odnosno prema sedam hrvatskih Sveučilišta. U državnom proračunu se osiguravaju sredstva za financiranje visokog obrazovanja i to kao dio proračuna nadležnog ministarstva. Ministarstvo dodjeljuje sredstva visokim učilištima i isplaćuje ih preko poslovnih banaka na račune visokih učilišta. Kada se planiraju proračunska sredstva za financiranje javno dostupnog obrazovanja, fakulteti sa statusom pravne osobe ne nastupaju samostalno prema nadležnom Ministarstvu, već u sklopu Sveučilišta. Fakulteti planiraju prihode i rashode, dostavljaju financijske planove Sveučilištu, Sveučilište sintetizira financijske planove fakulteta i zahtijeva od nadležnog ministarstva financiranje javnog obrazovanja ukupnim iznosom za sve sastavnice, a sve to s ciljem dobivanja dovoljnog iznosa za

pokrivanje osnovnih troškova izvedbe djelatnosti i poslovanja. Prema [19, str. 18] „MZOŠ predviđa da će Sveučilišta kroz *lump sum* model financiranja preuzeti institucionalnu odgovornost za upravljanje i financiranje visokih učilišta u svom sastavu. Sveučilišta će godišnje dobivati paušalni iznos dotacija iz državnog proračuna te ih na temelju utvrđenih kriterija dodjeljivati visokim učilištima.“ *Lump sum* model financiranja je u Republici Hrvatskoj još uvijek u fazi uvođenja, a ne može zaživjeti sve dok se ne utvrde jasni i pravedni kriteriji dodjele sredstava i dok se ne ujednači način obračuna troškova na svim visokim učilištima u RH. S druge strane MZOŠ još uvijek ne raspolaže transparentnim sustavom praćenja stvarnih troškova visokih učilišta te paušal isplaćuje prema podacima o proračunu iz prethodnih godina te povijesnim praćenjem isplaćenih iznosa, a ne prema stvarnim analitičkim podacima.

Izvjешćivanje se izvodi na sličan način vertikalno odozdo prema gore (od fakulteta preko Sveučilišta, do nadležnog Ministarstva). Realizacija financiranja kroz proračun je ponešto složenija i ovisi o namjeni sredstava (npr. obračun plaća zaposlenika i isplate tih plaća se provode ili izravno na račune fakulteta ili na račune zaposlenika, ovisno o nastavnim i znanstvenim zvanjima), a uglavnom se svodi na isplatu iz državnog proračuna na račun visokog učilišta u poslovnoj banci, ili preko FINA-e za korisnike proračunskih sredstava s računima u Hrvatskoj poštanskoj banci.

Fakulteti u RH imaju izrazito raznolike pozicije u proračunu Sveučilišta, uglavnom naslijeđene iz vremena kada se proračun planirao u nadležnom Ministarstvu te su stoga i njihovi prioriteti u upravljanju vlastitim resursima raznolikih orijentacija. Nepovoljna pozicija u proračunskoj shemi, sporost u mijenjanju relativnih odnosa s ostalim fakultetima, nerazmjerna opterećenost resursa po djelatnostima vodi ka potrebi za uvođenjem promjena u načinu upravljanja postojećim resursima te promjena u stjecanju vlastitih prihoda.

Iz prethodno navedenog, može se zaključiti kako **model financiranja visokog učilišta određuje način planiranja i upravljanja financijskim i drugim resursima visokih učilišta**. Prema Hunjaku [37, str. 97-98], „najopćenitiji cilj primjene proračunskih modela je osiguranje zadovoljenja društvenih potreba racionalnim korištenjem sredstava“, a „u pravilu dio proračuna (manji, često ne veći od 10%) raspoređuje se uz pomoć formule s ciljem poticanja aktivnosti koje omogućuju postizanje određenih

strateških ciljeva visokih učilišta“. **Kako bi se osigurala transparentnost i protočnost financijskih tokova između izvora i korisnika financiranja, nužno je odrediti podatkovnu osnovu informacijskog sustava visokog učilišta koja opisuje i nudi valjane podatke za upravljanje financijskim resursima na različitim razinama upravljanja i u različitim institucijama.**

2.4. Osnovni resursi visokih učilišta

Resursima visokih učilišta možemo smatrati sljedeće tipove i oblike resursa:

- Ljudi koji sudjeluju u izvedbi djelatnosti visokih učilišta: student, nastavnik, znanstvenik, stručnjak;
- Usluge i proizvodi: nastavni plan i program, predmet, znanstveni doprinos, stručni doprinos;
- Materijalna i financijska sredstva: tehnička infrastruktura, novac, oprema.

Resurse koji su od značaja za analizu načina planiranja i upravljanja resursima u visokim učilištima, su opisani u tablici 2.2. U prvom stupcu su abecednim redom navedeni nazivi resursa, a u drugom opis značenja resursa.

Tablica 2.2.: Popis i opis ključnih resursa visokih učilišta

Naziv resursa	Opis značenja resursa
Nastavni plan i program	Plan i program studija kojeg ustrojava i izvodi visoko učilište, a čijim završavanjem student stječe visoku naobrazbu i odgovarajući stručni naziv ili akademski stupanj.
Nastavnik	Osoba koja izvodi nastavu na visokom učilištu. Bez ovog entiteta se većina poslovnih procesa nastavne djelatnosti ne može odvijati.
Novac	Financijski resursi visokog učilišta, prikupljeni iz raznih izvora, namijenjeni nastavnoj, znanstvenoj i stručnoj djelatnosti.
Novo primijenjeno znanje - stručni doprinos	Objavljeni rad, knjiga, proizvod, usluga, projekt, inovacija, receptura, metodika ili neki drugi oblik rezultata stručnog rada ili rada na komercijalnom projektu. Veže se uvijek na entitet Stručnjak, a važan je za evaluaciju stručnog rada.
Novo temeljno znanje - znanstveni doprinos	Objavljeni rad, knjiga, patent, projekt, inovacija, receptura, metodika ili neki drugi oblik rezultata znanstveno istraživačkog rada. Veže se uvijek na entitet Znanstvenik, a važan je za evaluaciju znanstvenog rada.

Predmet	Jedinica nastavne djelatnosti, sastavni element Nastavnog plana i programa. Veže se uz entitet Nastavnik, a važan je za evaluaciju nastavnog rada. Veže se i uz entitet Student jer određuje kvalifikacije studenta.
Stručnjak	Osoba koja se bavi radom na stručnim ili komercijalnim projektima i programima visokog učilišta. Bez ovog entiteta se većina poslovnih procesa stručne i komercijalne djelatnosti visokog učilišta ne može odvijati.
Student	Osoba koja pohađa studijski program visokog učilišta. Upisom na studijski program postaje privremeni entitet visokog učilišta jer bez tog entiteta nema izvedbe nekih poslovnih procesa, npr. ne može se izvoditi nastava ako nema studenata.
Tehnička infrastruktura i oprema	Tehnička infrastruktura obuhvaća zgrade, dvorane, laboratorije, komunikacijske veze i drugu infrastrukturnu opremu koja je potrebna za izvedbu poslovnih procesa visokog učilišta.
Znanstvenik	Osoba koja se bavi znanstvenim ili umjetničkim radom na visokom učilištu. Bez ovog entiteta se većina poslovnih procesa znanstvene djelatnosti visokog učilišta ne može odvijati.

Produktivnost ljudskih resursa se mjeri planiranim i ostvarenim aktivnostima nastavnika/ znanstvenika/ stručnjaka u postizanju ciljanih rezultata u nastavnim obavezama/ znanstvenom doprinosu/ i stručnom doprinosu. Svjesno opredjeljenje za jačanje nekih aktivnosti (nastavnih, znanstvenih ili stručnih) u određenom vremenskom periodu je sredstvo upravljanja ljudskim resursima visokih učilišta te je u tom slučaju ciljano planirano i provedeno radi iskorištenja ključnih konkurentskih prednosti (npr. u stjecanju dodatnih prihoda ili u stjecanju ključnih stručnih referenci).

Kvalitetni nastavni programi, razvijeni predmeti s iskazanim ishodima učenja nužnim za postizanje željenih kompetencija studenata, tehnička infrastruktura i raspoloživost nastavnika, uz dobro organiziranu i kvalitetno izvođenu nastavu, temelj su za uspješno ostvarenje obrazovno-nastavne misije visokih učilišta.

Svi navedeni resursi se koriste za obavljanje djelatnosti visokih učilišta. Racionalno korištenje podrazumijeva planiranje upotrebe resursa u aktivnostima i procesima kojima se izvodi djelatnost, upravljanje vođeno planovima i praćenje realizacije planova po vremenskoj i troškovnoj dimenziji. Kvalitetno planiranje, upravljanje i praćenje realizacije plana korištenja resursa je nezamislivo bez odgovarajuće potpore informacijskim sustavom. Stoga u nastavku valja istražiti kako se planiraju, koriste i prate resursi visokih učilišta u procesima izvedbe djelatnosti.

2.5. Primjena metode Balanced Scorecard u upravljanju visokim učilištem

Upravljanje visokim učilištima mora biti određeno strateškim ciljevima koji se žele postići. Strateški ciljevi proizlaze iz vizije organizacije, trajanje im je ograničeno vremenskim razdobljem trajanja vizije, te predstavljaju okvire unutar kojih se upravlja visokim učilištem. Konkretizacija strateških ciljeva ima za cilj raspoređivanje i korištenje određenih resursa, te aktivnosti njihove transformacije u korist organizacije. S obzirom na usmjerenost vizije, a time i strateških ciljeva visokog učilišta, razlikujemo:

- **Upravljanje usmjereno na ostvarenje društvenog doprinosa:** Glavni strateški ciljevi se odnose ostvarenje misije postojanja, odnosno generiranja društvenog doprinosa kroz izvrsnost u nastavnoj, znanstvenoistraživačkoj i stručnoj djelatnosti. Svi resursi visokog učilišta se planiraju, koriste i troše s ciljem postizanja kvalitete načina izvedbe djelatnosti i kvalitete izlaznih proizvoda i usluga. Pritom je upravljanje troškovima sekundarna briga, a društveni doprinos primarna orijentacija.
- **Upravljanje usmjereno na profit:** općenito, organizacije mogu biti profitno ili neprofitno orijentirane. Visoka učilišta tako možemo razmatrati kao profitno orijentirana (kakva u praksi uglavnom jesu) ili kao neprofitno orijentirana (npr. visoka učilišta financirana iz zaklada čija je misija čvrsto povezana sa nekim aspektom društvene odgovornosti). S druge strane državna visoka učilišta u pravilu ne možemo razmatrati kao organizacije prvenstveno usmjerene na profit zbog njihove društvene uloge. Možemo reći da državna visoka učilišta, kao organizacije koje se financiraju iz državnog proračuna, moraju upravljati troškovima kao i profitna poduzeća, ali ne na način da to smanjuje kvalitetu rada prema korisnicima usluga. Stoga profitni učinak ne može biti jedini pokazatelj uspješnosti ili mogućnosti opstanka državnog visokog učilišta.
- **Upravljanje usmjereno na operativnu učinkovitost:** visoka učilišta samostalno upravljaju svojim resursima postavljajući vlastite uvjete i pravila prema raspoloživim sredstvima – kojim iznosom raspolažu, tim iznosom upravljaju. Pravila određuje tržište, plitka organizacijska struktura omogućava fleksibilnost, a raspoloživa sredstva ovise o sposobnosti upravitelja (menadžera privatnih visokih

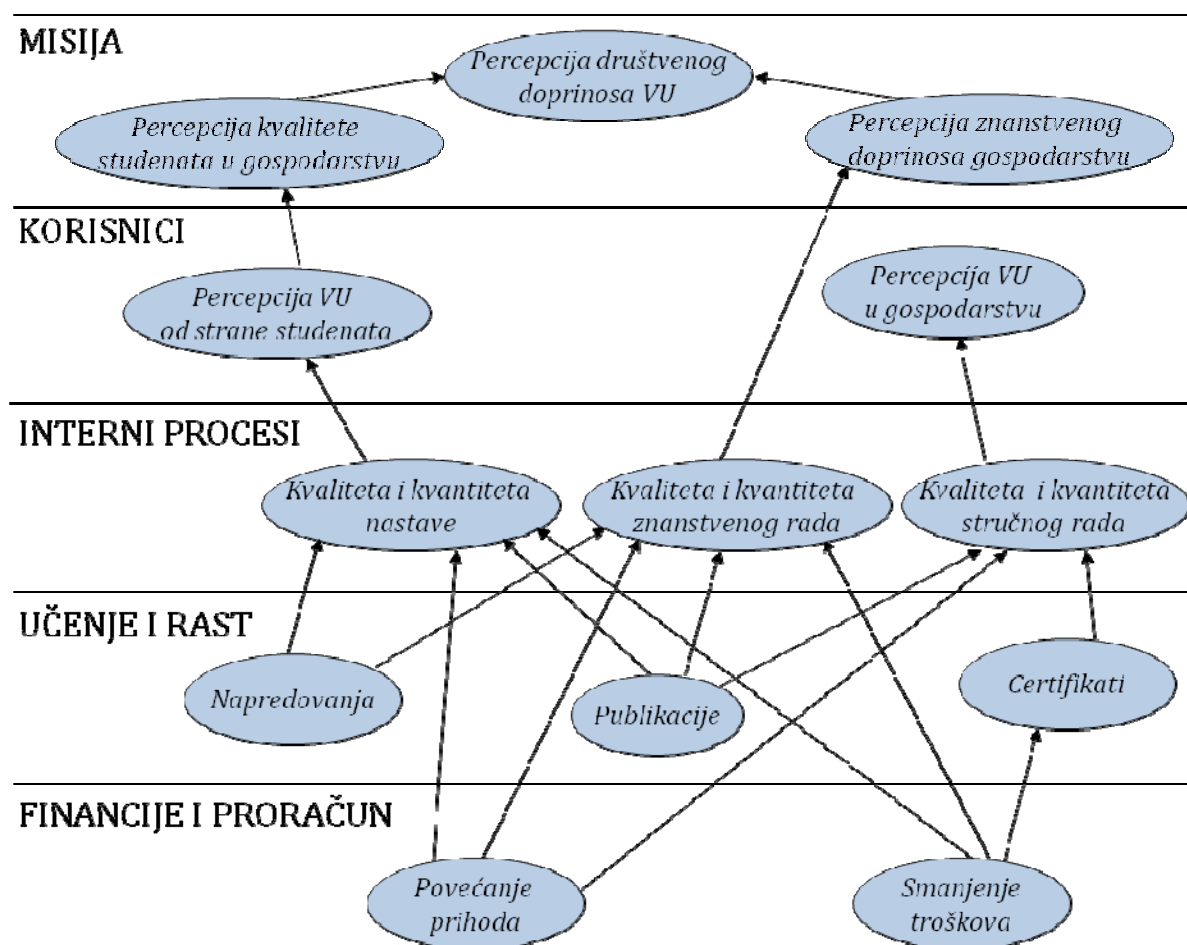
učilišta s odgovarajućom titulom) da prikupi i osigura financiranje djelatnosti. Državna visoka učilišta financijski značajno ovise državnom proračunu te samo do određene granice mogu autonomno upravljati vlastitim resursima (zapravo je i pitanje koja su vlastita sredstva visokog učilišta). Duga tradicija autonomije, položaj u društvu, hijerarhijska dubina organizacijskog ustroja, složeni upravljački odnosi, ponekad rade protiv institucije, usporavaju državna visoka učilišta u prilagodbi promjenama te pridonose manjoj operativnoj učinkovitosti od privatnih visokih učilišta.

Promjene u financiranju tjeraju visoka učilišta da probude vlastitu svijest o nužnosti učinkovitog planiranja i upravljanja resursima kao važnog čimbenika opstanka državnih visokih učilišta u kompetitivnom okruženju u kojem jača privatni sektor visokog obrazovanja. S jedne strane nije dovoljno samo primijeniti neke metode korporativnog upravljanja iz poslovnog sektora za planiranje i upravljanje resursima poduzeća, već i metode upravljanja učinkovitošću.

Metoda koja ne isključuje niti jedan od prethodno navedena tri pristupa, već ih dapače objedinjava, a primjenjiva je u visokim učilištima za mjerenje učinkovitosti (enlg. Performanse management) jest metoda uravnoteženog bodovnog sustava ili skraćeno BSC (od *engl. Balanced Scorecard*) autora Kaplana i Nortona [46]. Prema Kettunen i Kantola [49], primjena BSC-a u upravljanju visokim učilištem treba biti ugrađena u informacijski sustav visokog učilišta. Dobrović et. al. [18], tvrde da implementacija BSC metode u javnom sektoru doprinosi i vodi organizaciju prema ostvarenju ciljeva izvedbom aktivnosti s optimalnim korištenjem resursa organizacije. Bruijin [8] navodi primjere kako pratiti uspješnost visokih učilišta temeljem „proizvoda“ koje visoko učilište pruža: „Izvedba nastavne djelatnosti je aktivnost koju treba mjeriti sa više aspekata i kao takva je teško mjerljiva, dok je s druge strane vrijeme potrebno za ispravljanje ispita mjerljiv faktor“. Tilaye [89] tvrdi da BSC može biti alat upravljanja koji će instituciju prisiliti da identificira ključne faktore koji doprinose uspješnom ostvarenju zadanih ciljeva i time ostvarenju misije postojanja.

Mjerenje uspješnosti organizacije osigurava vodstvu organizacije pomoć u upravljanju kroz nekoliko perspektiva, čiji se redoslijed u hijerarhijskoj mapi ciljeva razlikuje za prvenstveno neprofitne organizacije (kao što su visoka učilišta koja se financiraju iz

državnog proračuna i usmjerena su prvenstveno ostvarenju misije) i izrazito profitno orijentirane organizacije i poduzeća. Visoka učilišta koja su prvenstveno usmjerena ka ostvarenju misije izvode djelatnosti s ciljem povećanja prihoda, a pri tom troškovi djelovanja moraju ostati unutar granica predviđenih novčanih sredstava u proračunu. Stoga se raspored perspektiva unutar kojih se postavljaju ciljevi, akcije i mjere ostvarenja ciljeva razlikuju za neprofitne i profitne organizacije (Brumec, [9]). Na slici 2.5. je prikazan prijedlog rasporeda perspektiva za visoka učilišta unutar kojih su razmješteni generički ciljevi izvođenja djelatnosti koji čine osnovnu strukturu ciljeva za visoka učilišta. Perspektiva Financije i proračun obuhvaća dva generička cilja koja su određena proračunom visokog učilišta: povećanje prihoda i smanjenje troškova. Definiranje stvarnih ciljeva u ovoj perspektivi ovisi o strategiji izvedenoj iz vizije za buduće razdoblje. Usmjerenje na povećanje prihoda ili smanjenje troškova unutar granica proračuna visokog učilišta, utječe na kvalitetu obavljanja svih djelatnosti visokih učilišta, kao i uspjesi u perspektivi Učenja i rasta, kao što su napredovanja, publikacije i certifikati. Kvaliteta izvođenja Internih procesa utječe na percepciju visokog učilišta dviju grupa korisnika: studenata i poduzeća za koje se provode stručni projekti. U perspektivi ostvarenja misije se nalaze ciljevi koji pokazuju kako je dobro visoko učilište alociralo resurse za postizanje ciljeva, a to su percepcija kvalitete studenata na tržištu rada i percepcija znanstvenog doprinosa visokog učilišta razvoju društva.



Slika 2.5.: Prijedlog rasporeda perspektiva i osnovne strukture ciljeva za visoka učilišta

Za učinkovitu primjenu metode BSC u upravljanju poslovanjem organizacija mora definirati svoju misiju postojanja, viziju u vremenskom razdoblju, strategije ostvarenja vizije i ciljeve čijim će se mjerenjem pratiti realizacija strategija. Za ostvarenje ciljeva treba planirati akcije i resurse koji će omogućiti ostvarenje ciljeva. Stoga operativno korištenje metode BSC mora biti povezano s tipičnim upravljačkim procesima kao što su: planiranje i upravljanje resursima, praćenje i nadzor poslovanja.

2.6. Analiza strukture sustava i okruženja visokih učilišta

Ustroj svakog visokog učilišta utječe na sustav planiranja i upravljanja resursima visokih učilišta. Kompleksnost sustava planiranja i upravljanja resursima se povećava s povećanjem hijerarhijskih razina organizacijske složenosti. Upravljanje visokim učilištem u užem smislu je složeno samo po sebi, međutim ako je pritom visoko učilište

dio nekog njemu nadređenog tijela, kao što to može biti neko drugo visoko učilište, onda zahtjevi na informacijski sustav koji treba podržavati poslovanje tih organizacija također postaju složeniji.

Informacijski sustav ne postoji sa za sebe ili sam po sebi, on se planira, projektira, razvija i uvodi sa svrhom potpore procesima koji omogućavaju ostvarenje ciljeva organizacije. Možemo ga smatrati dijelom organizacijskog sustava. Prema Brumecu i Vrčeku [11], „Unaprijed definirani ciljevi i način njihova ostvarenja (ili poslovni procesi), kao i interna organizacijska struktura realnog sustava, određuju informacijski sustav. Stoga zaključujemo da zahtjevi na informacijski sustav proizlaze iz općeg modela funkcioniranja organizacijskog sustava.“ Autori nadalje smatraju da je genetička⁷ definicija IS-a sljedeća: „Informacijski sustav je podsustav organizacijskog sustava, čija je zadaća povezivanje procesa na operativnoj (izvršnoj), upravljačkoj i razini odlučivanja s ciljem povećanja operativne efikasnosti, kvalitete upravljanja i pouzdanosti odlučivanja.“ U tom kontekstu valja razlikovati procese organizacije na tri razine: izvođenja, upravljanja i odlučivanja. Razina izvođenja obuhvaća procese temeljne poslovne djelatnosti kojima se ostvaruje misija postojanja organizacije, generira profit, koji su prepoznatljivi krajnjim korisnicima kao poslovi kojima se proizvodi proizvod ili usluga, koji imaju učestalu interakciju s okruženjem i koji omogućavaju transformaciju ulaznih tokove (*engl. Inputs*) u izlazne (*engl. Outputs*). Tokovi koje procesi izvođenja koriste mogu biti materijalni (oprema, zgrade, isl.), ljudski (studenti, partneri, isl.) i nematerijalni (natječaji, podaci, isl.). Sljedeća razina procesa je razina upravljanja, a ona obuhvaća procese planiranja, odobravanja, nadziranja i organiziranja procesa razine izvođenja, uzimajući u obzir povratne informacije i utjecaje iz okoline. Najviša razina procesa je razina odlučivanja za koju je karakteristično to što obuhvaća određivanje okvira u kojima se ostali procesi izvode, definiranje misije, vizije i ciljeva organizacije, za što je nužno osigurati nositeljima ovih procesa da raspolažu točnim i pravovremenim informacijama. Ne treba zaboraviti utjecaj okruženja na organizacijski sustav i njegove procese, kao niti smetnje koje mogu ometati normalan tijek izvođenja temeljne djelatnosti.

⁷ Prema riječi genesis

U kontekstu prethodno napisanoga, ako izradimo model funkcioniranja visokog učilišta, onda iz njega možemo zaključivati o zahtjevima na informacijski sustav. Drugim riječima, ako želimo odrediti kako treba izgledati informacijski sustav visokih učilišta, onda trebamo definirati poslovne zahtjeve koji proizlaze iz modela funkcioniranja visokog učilišta.

Na slici 2.6. se prikazuju odnosi koji vrijede za visoko učilište u užem smislu. U radu će se pod pojmom visokog učilišta smatrati pravni subjekt s pravima i obvezama koje iz tog statusa proizlaze (samostalnost u izvođenju poslova, financijska odgovornost, vlastite strukture odlučivanja). Pod visokim učilištem u užem smislu smatra se svaka visokoobrazovna institucija koja unutar sebe nema pravnih subjekata kao sastavnica te institucije. Tako prikaz može opisivati rad sveučilišta (*engl. University*) ako njegove sastavnice nemaju pravnu samostalnost (i/ili ne djeluju samostalno na tržištu, odnosno nemaju podređenu pravnu osobu) ili fakultet s pravnom osobnošću (kao što je to slučaj u RH).

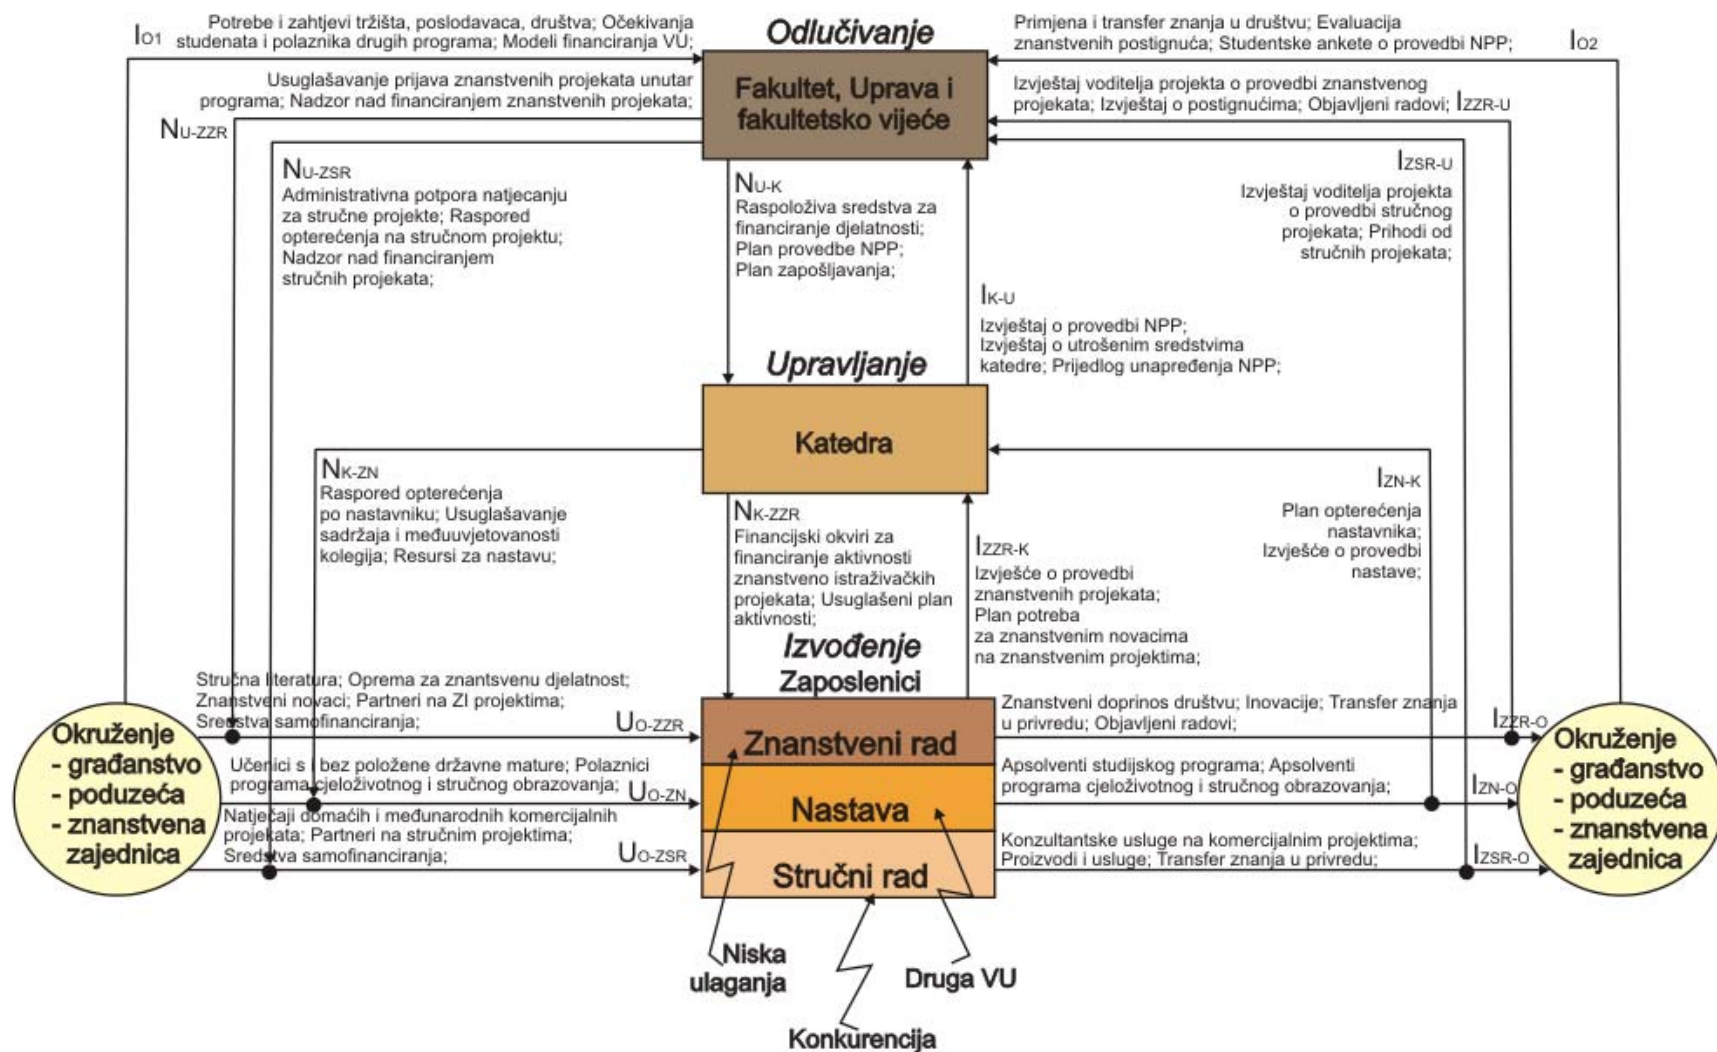
Na razini izvođenja se izvršavaju poslovi vezani temeljne djelatnosti fakulteta (ili znanstveni rad, nastavu i stručni rad). Iz okruženja dolaze ulazni tokovi koji su potrebni za izvođenje djelatnosti, a nositelji tih poslova su nastavnici, znanstvenici i drugi zaposlenici. Tri temeljne djelatnosti fakulteta imaju vlastite cikluse izvršavanja koji obuhvaćaju sljedove procesa za transformaciju ulaznih tokova u izlazne. Djelatnosti su međusobno povezane tako da se rezultati znanstveno istraživačkog rada koriste u nastavi kao teoretske osnove predmeta, dok se rezultati stručnog rada prezentiraju kao praktična iskustva i primjeri primjene teorije u praksi. Kroz nastavu se obučavaju kadrovi koji ta znanja prenose u društvo i omogućavaju primjenu znanstvenih i stručnih postignuća ciljano u gospodarstvu.

Na razini upravljanja se provode poslovi vezani uz planiranje, organizaciju, nadzor i koordinaciju poslova izvođenja, a u nadležnosti su katedri (ili drugih ustrojstvenih jedinica visokog učilišta koje imaju jednaku ulogu u instituciji). Katedre su zadužene za stvaranje preduvjeta izvedbe operativnih procesa u skladu sa zadanim ciljevima institucije, praćenje mjera ciljeva i izvješćivanje o ostvarenju ciljeva, koordinaciju i raspoređivanje opterećenja zaposlenika, usklađivanje i planiranje kadrovskih promjena za znanstveno područje katedre te druge poslove upravljanja nad operativom.

Razina odlučivanja obuhvaća poslove koordinacije s okruženjem, planiranja i praćenja misije, vizije i ciljeva poslovanja, definiranje poslovnih pravila i procedura, odobravanje i motiviranje zaposlenika, kao i osiguravanja financijskih i drugih resursa potrebnih za provedbu djelatnosti.

Okruženje također utječe na instituciju tako što pruža osnovne resurse i koristi proizvode ili usluge koje institucija generira. Sve se to odvija pod utjecajem vanjskih smetnji, na koje institucija može vrlo slabo ili ne može nikako utjecati.

Na slici 2.6. je dan prikaz genetičke definicije informacijskog sustava visokog učilišta u užem smislu. U tablici 2.3. su u prvom stupcu navedeni oznaka, naziv sadržaja veza objekata prikaza, a u drugom opis sadržaja i funkcionalni zahtjevi na informacijski sustav.



Slika 2.6.: Genetička definicija informacijskog sustava visokog učilišta u užem smislu

Tablica 2.3.: Popis i opis sadržaja veza objekata modela

Oznaka i naziv sadržaja veze	Opis sadržaja veze
IK-U Izvještaj o provedbi NPP; Izvještaj o utrošenim sredstvima katedre; Prijedlog unapređenja NPP;	<p>Voditelj katedre prikuplja podatke o realizaciji plana nastave te izvješćuje upravu visokog učilišta o provedbi nastave, u ime katedre daje prijedloge zapošljavanja novih nastavnika, prema prijedlozima nastavnika predlaže promjene predmeta i njihove međuuvjetovanosti, podnosi izvješće o utrošenim financijskim sredstvima namijenjenim razvoju kompetencija i opremljenosti članova katedre, daje prijedloge unapređenja nastavnog plana i programa.</p> <p><i>Aplikacija treba omogućiti planiranje i praćenje izvršenja nastave, planiranje i raspoređivanje opterećenja nastavnika, planiranje i trošenje financijskih sredstava proračuna katedre, planiranje i usuglašavanje predmeta nastavnog plana i programa, te napredovanje nastavnika u nastavnim zvanjima.</i></p> <p><i>Ključni podaci su: Nastavnik, Nastavni plan i program, Predmet, Međuuvjetovanost predmeta, Oprema, Plan nastavnog opterećenja, Evidencija realizacije nastave, Proračun katedre, Napredovanje u zvanju.</i></p>
IO1 Potrebe i zahtjevi tržišta, poslodavaca, društva; Očekivanja studenata i polaznika drugih programa; Modeli financiranja VU;	<p>Okruženje visokog učilišta u užem smislu čine građani, država, gospodarski subjekti i akademska zajednica. Oni prema visokom učilištu imaju različita očekivanja i uloge. Studenti žele stjecati akademska znanja i zvanja, poslodavci žele obrazovane stručnjake, gospodarstvo očekuje nova znanstvena postignuća i tehnologije, država očekuje primjenu i transfer znanja u gospodarstvo. Pritom svatko od njih na neki način sudjeluje u financiranju visokih učilišta izravno financiranjem određenih djelatnosti ili neizravno kroz poreze.</p> <p><i>Aplikacija visokog učilišta treba omogućiti evidenciju poslovnih partnera (subjekata iz okruženja) i ugovaranje oblika suradnje ili odnosa s visokim učilištem.</i></p> <p><i>Ključni podaci su: Poslovni parter, Ugovor o suradnji, Oblik suradnje, Kontni plan, Planirane stavke proračuna VU.</i></p>
IO2 Primjena i transfer znanja u društvu; Evaluacija znanstvenih postignuća; Studentske ankete o provedbi NPP;	<p>Povratne informacije iz okruženja o kvaliteti studijskih programa, kvaliteti studenata, primjeni znanstvenih i stručnih postignuća.</p> <p><i>Aplikacija treba podržavati prihvatanje i obradu povratnih informacija iz okruženja (studenata i apsolviranih, građanstva, poduzeća, šire znanstvene zajednice) kako bi se unapređivale djelatnosti visokog učilišta. Neki od mogućih oblika povratnih informacija su podaci iz anketa, evidencija citiranih radova i drugi oblici referenciranja objavljenih radova, praćenje objavljenih članaka u javnim glasilima i novinama (engl. pressclipping) i drugo.</i></p> <p><i>Ključni podaci su: Studentske ankete, Nastavni plan i program, Reference radova.</i></p>

<p>IZN-K</p> <p>Plan opterećenja nastavnika; Izvješće o provedbi nastave;</p>	<p>Plan aktivnosti izvedbe nastave za nastavnike katedre i izvješća o realizaciji nastave.</p> <p>Nositelji predmeta i nastavnici planiraju nastavno opterećenje prema broju upisanih studenata na predmet, predviđenoj satnici nastave i nastavnim oblicima (predavanja, laboratorijske vježbe, seminarska nastava, auditorne vježbe i drug nastavni oblici), kvalifikacijama nastavnika, veličini grupe studenata po obliku nastave. Nakon izvedbe nastave, nastavnici evidentiraju realizirane sate u nastavi te podnose izvješće katedri.</p> <p><i>Aplikacija treba omogućavati planiranje nastavnih obveza, raspoređivanje nastavnika na predmete, evidenciju realizirane nastave, izvješćivanje o provedbi nastave.</i></p> <p><i>Ključni podaci su: Nastavnik, Predmet, Nastavni plan i program, Nastavni oblici predmeta, Plan nastavnog opterećenja, Evidencija o realizaciji nastave.</i></p>
<p>IZN-O</p> <p>Apsolventi studijskog programa; Apsolventi programa cjeloživotnog i stručnog obrazovanja;</p>	<p>Rezultat nastavne djelatnosti visokog učilišta u užem smislu. Studenti koji su upisom na studijski program ili program cjeloživotnog obrazovanja postali privremeni resursi visokog učilišta, nakon završetka studija napuštaju visoko učilište sa stečenim akademskim zvanjem.</p> <p><i>Aplikacija treba podržavati upis studenata na studijski program, upis polaznika stručnih obrazovnih programa obrazovanja, dodjelu prava i obveza svim studentima i drugim korisnicima programa obrazovanja, upis studenata na predmeta, planiranje i praćenje izvršenja nastave, evidenciju kolokvija i ispita, formiranje predmeta, pripremu i distribuciju nastavnih materijala, evidenciju uspjeha (ocjena) studenata po predmetima ili drugim obvezama koje nose ECTS bodove.</i></p> <p><i>Ključni podaci su: Studenti, Studijski programi, Kvalifikacije učenika (državna matura), Predmet, Aktivnosti u nastavi, Nastavni plan i program, Nastavnici, Ispiti, Završni radovi, Mentori, Plan nastavnog opterećenja, Evidencija o realizaciji nastave.</i></p>
<p>IZSR-O</p> <p>Konzultantske usluge na komercijalnim projektima; Proizvodi i usluge; Transfer znanja u privredu;</p>	<p>Rezultat rada na stručnim i komercijalnim projektima: objavljeni rad, knjiga, patent, projekt, inovacija, receptura, metodika, programsko rješenje ili neki drugi proizvod/usluga nastao tijekom projekta. Važan je za evaluaciju stručnog rada. Stručni doprinos treba naći svoju primjenu u privredi (društvu), a aktivnosti transfera znanja mogu biti održavanje seminara, tečajeva, suradnjom s poduzećima na zajedničkim razvojnim projektima i druge aktivnosti.</p> <p><i>Aplikacija mora podržavati evidenciju aktivnosti i rezultata rada članova projektnog tima i praćenje znanstvenih postignuća znanstvenika.</i></p> <p><i>Ključni podaci su: Stručnjak, Stručni projekti, Poslovni partneri (poduzeća i visoka učilišta), Stručni doprinos, Aktivnosti na stručnim projektima, Plan opterećenja na stručnim projektima.</i></p>

<p>IZSR-U</p> <p>Izveštaj voditelja projekta o provedbi stručnog projekata; Prihodi od stručnih projekata;</p>	<p>Izvešća o provedbi i postignućima stručnih i komercijalnih projekata u sažetom obliku i rezultati projekta važni za evaluaciju stručnog rada zaposlenika visokog učilišta.</p> <p>Tijekom i nakon provedbe projekta, voditelj projekta izvješćuje upravu o realizaciji aktivnosti na stručnom ili komercijalnom projektu, ostvarenim rezultatima prihodima i troškovima.</p> <p><i>Aplikacija treba omogućavati planiranje i praćenje aktivnosti stručnog ili komercijalnog projekta, planiranje i praćenje realizacije proračuna projekta, planiranje i praćenje opterećenja stručnjaka, evidenciju objavljenih radova (rezultata projekta), planiranje nabave opreme.</i></p> <p><i>Ključni podaci su: Proračun projekta, Plan opterećenja na SK projektima, Stručnjak, Stručni i komercijalni projekti, Poslovni partneri (fondovi, poduzeća i visoka učilišta), Oprema.</i></p>
<p>IZZR-K</p> <p>Izvešće o provedbi znanstvenih projekata; Plan potreba za znanstvenim novacima na znanstvenim projektima;</p>	<p>Plan potreba za provedbu znanstveno istraživačke djelatnosti i povratne informacije u obliku izvješća o provedbi znanstveno istraživačke djelatnosti.</p> <p>Znanstvenici planiraju znanstveno istraživačke projekte te ih prijavljuju na natječeaje kako bi osigurali financiranje. Planiraju se aktivnosti projekta, rokovi, sudionici i partneri (znanstvenici, znanstveni novaci, partnerska visoka učilišta), potrebna oprema i drugo. Plan se analizira na razini katedre kako bi se uskladilo opterećenje zaposlenika u različitim djelatnostima te kako bi se sredstvima namijenjenima katedri financirala studijska putovanja i druge aktivnosti znanstveno istraživačkog rada. Tijekom i nakon provedbe projekta, evidentira se stvarno opterećenje znanstvenika.</p> <p><i>Aplikacija treba omogućavati planiranje i praćenje aktivnosti znanstveno istraživačkog projekta, planiranje i praćenje realizacije proračuna katedre, planiranje i praćenje opterećenja znanstvenika, evidenciju objavljenih radova (rezultata znanstveno istraživačkog rada), planiranje nabave opreme.</i></p> <p><i>Ključni podaci su: Proračun katedre, Plan opterećenja na znanstvenim projektima, Znanstvenik, Znanstveni projekti, Poslovni partneri (druga visoka učilišta), Oprema.</i></p>
<p>IZZR-O</p> <p>Znanstveni doprinos društvu; Inovacije; Transfer znanja u privredu; Objavljeni radovi;</p>	<p>Rezultat znanstveno istraživačkog rada: objavljeni rad, knjiga, patent, projekt, inovacija, receptura, metodika ili neki drugi proizvod/usluga nastao znanstveno istraživačkim radom. Važan je za evaluaciju znanstvenog rada. Znanstveni doprinos treba naći svoju primjenu u privredi (društvu), a aktivnosti transfera znanja mogu biti održavanje seminara, tečajeva, suradnjom s poduzećima na zajedničkim razvojnim projektima i druge aktivnosti.</p> <p><i>Aplikacija mora podržavati evidenciju aktivnosti i rezultata znanstveno istraživačkog rada članova projektnog tima i praćenje znanstvenih postignuća znanstvenika.</i></p> <p><i>Ključni podaci su: Znanstvenik, Znanstveni projekti, Poslovni partneri</i></p>

	<i>(poduzeća i visoka učilišta), Znanstveni doprinos, Plan opterećenja na znanstvenim projektima.</i>
<p>IZZU-U</p> <p>Izveštaj voditelja projekta o provedbi znanstvenog projekata;</p> <p>Izveštaj o postignućima;</p> <p>Objavljeni radovi;</p>	<p>Izvešća o provedbi i postignućima znanstveno istraživačke djelatnosti u sažetom obliku i rezultati znanstveno istraživačkog rada važni za evaluaciju znanstvenog rada na visokom učilištu.</p> <p>Tijekom i nakon provedbe projekta, voditelj projekta izvješćuje upravu o realizaciji aktivnosti na znanstveno istraživačkom projektu, ostvarenim rezultatima prihodima i troškovima.</p> <p><i>Aplikacija treba omogućavati planiranje i praćenje aktivnosti znanstveno istraživačkog projekta, planiranje i praćenje realizacije proračuna projekta, planiranje i praćenje opterećenja znanstvenika, evidenciju objavljenih radova (rezultata znanstveno istraživačkog rada), planiranje nabave opreme.</i></p> <p><i>Ključni podaci su: Proračun projekta, Plan opterećenja na znanstvenim projektima, Znanstvenik, Znanstveni projekti, Poslovni partneri (fondovi, poduzeća i visoka učilišta), Oprema.</i></p>
<p>NK-ZN</p> <p>Raspored opterećenja po nastavniku;</p> <p>Usuglašavanje sadržaja i međuvjetovanosti kolegija; Resursi za nastavu;</p>	<p>Upravljački nalozi i odluke za operativno izvođenje nastavne djelatnosti koje donosi katedra odgovarajućom procedurom (izglasavanjem, autonomijom pročelnika katedre, ili na neki drugi način).</p> <p>Nalozi i odluke se odnose na raspoređivanje opterećenja u nastavi za zaposlenike katedre, stručno usuglašavanje sadržaja i međuvjetovanosti predmeta u znanstvenom području djelovanja katedre, upravljanje financijskim sredstvima katedre namijenjenim nastavi. Izvedbom procesa nastavne djelatnosti izvješćuje se katedra o ostvarenjima, opisanim tokom IZN-K.</p> <p><i>Aplikacija treba omogućavati planiranje nastavnih obveza, raspoređivanje nastavnika na predmete, evidenciju realizirane nastave te izvješćivanje o provedbi nastave, definiranje i ažuriranje međuvjetovanosti predmeta, evidentiranje podataka o planiranju, nabavi i raspoređivanju opreme za nastavu.</i></p> <p><i>Ključni podaci su: Odluke, Nalog za izvedbu nastave, Nastavnik, Nastavni plan i program, Predmet, Međuvjetovanost predmeta, Oprema, Dvorane, Plan nastavnog opterećenja, Evidencija o realizaciji nastave.</i></p>
<p>NK-ZZR</p> <p>Financijski okviri za financiranje aktivnosti znanstveno istraživačkih projekata;</p> <p>Usuglašeni plan aktivnosti;</p>	<p>Usuglašavanje opterećenja zaposlenika i odluke za operativno izvođenje znanstveno istraživačke djelatnosti koje donosi katedra odgovarajućom procedurom (izglasavanjem, autonomijom pročelnika katedre, ili na neki drugi način).</p> <p>Nalozi i odluke se odnose na planiranje i raspoređivanje opterećenja u znanstveno istraživačkom radu za zaposlenike katedre, upravljanje financijskim sredstvima katedre namijenjenim znanstveno istraživačkom radu. Izvedbom procesa nastavne djelatnosti izvješćuje se katedra o ostvarenjima, opisanim tokom IZZR-K.</p>

	<p><i>Aplikacija treba omogućavati planiranje znanstveno istraživačkih obveza zaposlenika, raspoređivanje zaposlenika na znanstveno istraživačke projekte te izvješćivanje o provedbi projekata, evidentiranje podataka o planiranju, nabavi i raspoređivanju opreme za projekte, planiranje i realizaciju studijskih putovanja članova katedre.</i></p> <p><i>Ključni podaci su: Proračun katedre, Plan opterećenja na znanstvenim projektima, Znanstvenik, Znanstveni projekti, Oprema.</i></p>
<p>NU-K</p> <p>Raspoloživa sredstva za financiranje djelatnosti; Plan provedbe NPP; Plan zapošljavanja;</p>	<p>Visoko učilište svojim sastavnim jedinicama (npr. katedrama, ili odjelima) stavlja na raspolaganje određeni iznos za razvoj kompetencija članova katedre, nabavu opreme, studijska putovanja i drugo. Nadležno upravljačko tijelo (fakultetsko vijeće, uprava, dekan i prodekani) prema prijedlozima katedre (ili odjela) odobrava zapošljavanje novih suradnika, pokreće formalni postupak izbora i reizbora u zvanje te daje smjernice, upute i odluke vezane uz provedbu nastavnog plana i programa.</p> <p><i>Aplikacija treba podržavati planiranje i praćenje realizacije proračuna visokog učilišta, planiranje kadrova i zapošljavanje, praćenje razvoja kompetencija zaposlenika te planiranje i praćenje realizacije nastavnih planova i programa visokog učilišta.</i></p> <p><i>Ključni podaci su: Nastavnik, Predmet, Međuuvjetovanost predmeta, Oprema, Plan nastavnog opterećenja, Evidencija realizacije nastave, Proračun katedre, Napredovanje u zvanju, Nastavni plan i program.</i></p>
<p>NU-ZSR</p> <p>Administrativna potpora natjecanju za stručne projekte; Raspored opterećenja na stručnom projektu; Nadzor nad financiranjem stručnih projekata;</p>	<p>Nadležno upravljačko tijelo (fakultetsko vijeće, uprava, dekan i prodekani) odobrava prijedloge stručnih projekta. Odobreni prijedlozi natječajne dokumentacije projekata se prijavljuju na natječaj. Ako je projekt prihvaćen ili odabran u natječaju, ugovora se suradnja sa subjektom iz okruženja. Imenuje se voditelj stručnog projekta koji izvješćuje nadležno upravljačko tijelo o aktivnostima, rezultatima, prihodima i troškovima projekta.</p> <p><i>Aplikacija treba podržavati pripremanje prijave i natječajne dokumentacije projekata, ugovaranje projekta, planiranje i praćenje realizacije proračuna stručnog ili komercijalnog projekta, planiranje i praćenje aktivnosti na projektu, usuglašavanje opterećenja stručnjaka na projektima.</i></p> <p><i>Ključni podaci su: Proračun projekta, Plan opterećenja na stručnim projektima, Stručnjak, Stručni i komercijalni projekti, Stručni doprinos, Poslovni partneri (fondovi, poduzeća i visoka učilišta), Ugovor o suradnji, Oprema, Referencirani radovi.</i></p>
<p>NU-ZZR</p> <p>Usuglašavanje prijava znanstvenih projekata unutar programa; Nadzor nad financiranjem</p>	<p>Nadležno upravljačko tijelo (fakultetsko vijeće, uprava, dekan i prodekani) prema prijedlozima znanstvenika usuglašava planirane znanstveno istraživačke projekte na razini visokog učilišta. Usuglašeni projekti se prijavljuju na natječaj nadležnog ministarstva unutar jedinstvenog programa znanstvenog područja ili na natječaj nekog drugog potencijalnog izvora financiranja znanstvenog rada (npr. fondovi za razvoj). Voditelji projekata izvješćuju nadležno</p>

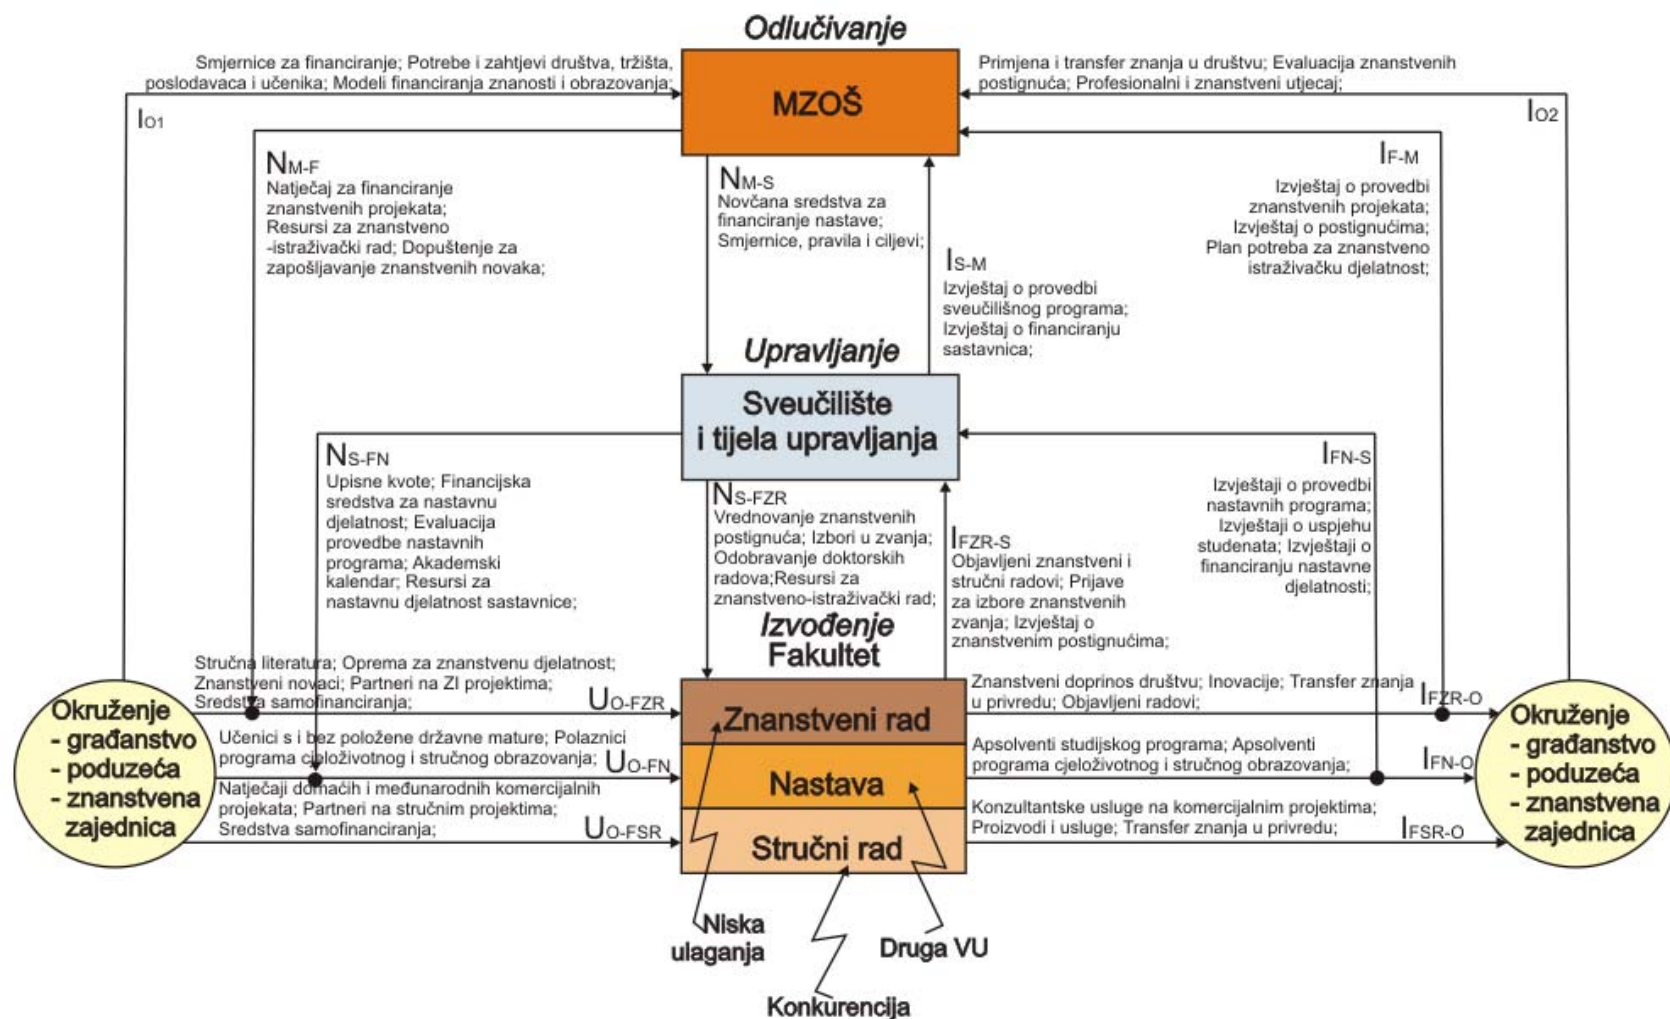
<p>znanstvenih projekata;</p>	<p>upravljačko tijelo o prihodima i troškovima projekta.</p> <p><i>Aplikacija treba podržavati ugovaranje projekta, planiranje i praćenje realizacije proračuna znanstveno istraživačkog projekta, planiranje i praćenje aktivnosti znanstvenih projekata, usuglašavanje opterećenja znanstvenika na projektima, pripremanje prijave projekata na natječaje.</i></p> <p><i>Ključni podaci su: Proračun projekta, Plan opterećenja na znanstvenim projektima, Znanstvenik, Znanstveni projekti, Znanstveni doprinos, Poslovni partneri (fondovi, poduzeća i visoka učilišta), Oprema, Referencirani radovi.</i></p>
<p>UO-ZN</p> <p>Učenici s i bez položene državne mature; Polaznici programa cjeloživotnog i stručnog obrazovanja;</p>	<p>Ulazni tokovi iz okruženja koji su potrebni za provedbu djelatnosti obrazovanja, odnosno nastave.</p> <p>Pod tim ulaznim resursima smatramo:</p> <ul style="list-style-type: none"> (a) Učenike s i bez položene državne mature – vanjske entitete koji privremeno (za vrijeme trajanja obrazovanja) postaju interni entiteti „studenti“ bez kojih se djelatnost ne bi mogla realizirati. (b) Polaznici programa cjeloživotnog i stručnog obrazovanja - vanjske entitete koji povremeno (svaki put za vrijeme trajanja ciklusa obrazovnog ili stručnog programa obrazovanja) postaju interni entiteti „studenti“ bez kojih se djelatnost ne bi mogla realizirati. <p>Svi se ovi ulazni tokovi posredstvom procesa transformiraju u izlazne tokove opisane pod oznakom IZN-O.</p> <p><i>Aplikacija treba podržavati upis studenata na studijski program, upis polaznika stručnih obrazovnih programa obrazovanja, dodjelu prava i obveza svih studenata i drugih korisnika programa obrazovanja, upis studenata na predmet, planiranje i praćenje izvršenja nastave, evidenciju kolokvija i ispita, formiranje predmeta, pripremu i distribuciju nastavnih materijala, evidenciju uspjeha (ocjena) studenata po predmetima ili drugim obvezama koje nose ECTS bodove.</i></p> <p><i>Ključni podaci su: Studenti, Studijski programi, Kvalifikacije učenika (državna matura), Predmet, Aktivnosti u nastavi, Nastavni plan i program, Nastavnici, Ispiti, Plan nastavnog opterećenja, Evidencija o realizaciji nastave.</i></p>
<p>UO-ZSR</p> <p>Natječaji domaćih i međunarodnih komercijalnih projekata; Partneri na stručnim projektima; Sredstva samofinanciranja;</p>	<p>Ulazni tokovi iz okruženja koji su potrebni za provedbu djelatnosti stručno komercijalnog rada na projektima za gospodarstvo ili općenito, društvo.</p> <p>Pod tim ulaznim resursima smatramo:</p> <ul style="list-style-type: none"> (a) natječaje domaćih i međunarodnih komercijalnih projekata – koji se objavljuju u raznim oblicima i formama te zahtijevaju individualni pristup svakom projektnom natječaju. Prate se u obliku publikacija, internetskih izvora, pozivnih natječaja i drugim oblicima.

	<p>(b) partnere na stručnim projektima – stručnjake drugih institucija koji mogu sudjelovati u stručnim i komercijalnim projektima institucije</p> <p>(c) Sredstva samofinanciranja – privatni i drugi izvori vlastitih prihoda visokog učilišta.</p> <p>Svi se ovi ulazni tokovi posredstvom procesa transformiraju u izlazne tokove opisane pod oznakom IZSR-O.</p> <p><i>Aplikacija treba podržavati vođenje evidentiranje podataka o stručnim i komercijalnim projektima, planiranje i raspoređivanje članova projektnih timova po aktivnostima projekta, planiranje, nabavu i raspoređivanje opreme za stručne i komercijalne projekte, evidenciju prihoda i troškova projekata.</i></p> <p><i>Ključni podaci su: Stručni i komercijalni projekti, Aktivnosti SK projekata, Oprema, Stručnjak, Planirane stavke proračuna fakulteta, Realizirane stavke proračuna fakulteta.</i></p>
<p>UO-ZZR</p> <p>Stručna literatura; Oprema za znanstvenu djelatnost; Znanstveni novaci; Partneri na ZI projektima; Sredstva samofinanciranja;</p>	<p>Ulazni tokovi iz okruženja koji su potrebni za provedbu djelatnosti znanstveno istraživačkog rada.</p> <p>Pod tim ulaznim tokovima smatramo:</p> <p>(a) stručnu literaturu – koja može biti u obliku publikacija, internetskih izvora, istraživačkih studija i drugim oblicima;</p> <p>(b) opremu za znanstvenu djelatnost – pod ovime se podrazumijeva oprema za laboratorijska istraživanja, ICT oprema i drugi materijalni resursi;</p> <p>(c) znanstvene novake - stručnjake koji će se baviti znanstveno istraživačkim radom i imaju potencijal nakon toga postati znanstvenik;</p> <p>(d) Partneri na ZI projektima – stručnjake drugih institucija koji mogu sudjelovati u znanstvenim projektima institucije;</p> <p>(e) Sredstva samofinanciranja – privatni i drugi izvori vlastitih prihoda visokog učilišta.</p> <p>Svi se ovi ulazni tokovi posredstvom procesa znanstveno istraživačkog rada transformiraju u izlazne tokove opisane pod oznakom IZZR-O.</p> <p><i>Aplikacija treba podržavati vođenje evidencije korištenja stručne literature u knjižnici visokog učilišta, evidentiranje podataka o znanstvenim projektima, planiranje aktivnosti i raspoređivanje članova projektnih timova po aktivnostima projekta, planiranje, nabavu i raspoređivanje opreme za znanstveno istraživački rad, evidenciju znanstvenika partnerskih visokih učilišta, evidenciju prihoda i troškova projekata.</i></p> <p><i>Ključni podaci su: Publikacije, Oprema, Znanstvenik, Poslovni partneri (druga visoka učilišta), Znanstveni projekti, Aktivnosti na projektima, Planirane stavke proračuna fakulteta, Realizirane stavke proračuna fakulteta.</i></p>

Specifičnost visokih učilišta u RH je tradicija visokih učilišta u širem smislu, odnosno pretežito funkcioniranje državno financiranog visokog obrazovanja u sklopu Sveučilišta sa sastavnicama koje imaju pravnu osobnosti – fakultetima. Stoga valja razmotriti i te odnose koji utječu na genetičku definiciju visokih učilišta u širem smislu. Slika 2.7. prikazuje proširenje genetičke definicije informacijskog sustava fakulteta kao visokog učilišta u širem smislu. Poziciju fakulteta treba promatrati kao dio Sveučilišta koje mu je izravno nadređeno i nadležnog ministarstva koje mu je djelomično izravno, a djelomično posredno nadređeno. Tako fakulteti djeluju istovremeno kao sastavnice nadređene institucije - Sveučilišta i sveučilištu nadređene institucije - nadležnog ministarstva, što nije specifičnost hrvatskih sveučilišta [15]. U tablici 2.4. su u prvom stupcu navedeni oznaka, naziv sadržaja veza objekata prikaza, a u drugom opis sadržaja i funkcionalni zahtjevi na informacijski sustav koji bi trebao pružati potporu ovako složenom organizacijskom sustavu.

Na razini izvođenja se izvršavaju temeljne djelatnosti fakulteta (nastava, znanstveno istraživački rad, stručni rad). Iz okruženja dolaze ulazni tokovi koji su potrebni za izvođenje djelatnosti. Na razini upravljanja su Sveučilište i sveučilišna tijela koja upravljaju nekim aspektom visokog obrazovanja (Vijeća područja, Matično povjerenstvo, Rektorat i druga tijela). Na razini odlučivanja se provode poslovni vezani uz organizaciju visokog obrazovanja, komunikaciju i koordinaciju na nacionalnoj razini. planiranjem i praćenjem nacionalnih ciljeva obrazovanja, definiranje modela financiranja, poslovnih pravila i procedura, osiguravanje financijskih i drugih resursa potrebnih za provedbu djelatnosti.

Okruženje također utječe na instituciju tako što pruža osnovne resurse i koristi proizvode ili usluge koje institucija generira. Sve se to opet odvija pod utjecajem vanjskih smetnji, na koje institucija može vrlo slabo ili ne može nikako utjecati.



Slika 2.7.: Proširenje genetičke definicije informacijskog sustava visokog učilišta u širem smislu

Tablica 2.4.: Popis i opis sadržaja veza objekata proširenog modela

Oznaka sadržaja veze	Opis sadržaja veze
IF-M Izvještaj o provedbi znanstvenih projekata; Izvještaj o postignućima; Plan potreba za znanstveno istraživačku djelatnost;	<p>Planovi vezani uz znanstveno istraživačku djelatnost i izvješća o provedbi i postignućima znanstveno istraživačke djelatnosti u sažetom obliku i rezultati znanstveno istraživačkog rada važni za evaluaciju znanstvenog rada zaposlenika na visokom učilištu.</p> <p>Fakulteti planiraju aktivnosti provedbe znanstveno istraživačke djelatnosti i opterećenja znanstvenika te najavljuju potrebe za uključivanjem novih znanstvenika. Tijekom i nakon provedbe projekta, fakulteti podnose izvješća o provedbi projekta, rezultatima rada na projektima i troškovima. Izvješća se u unaprijed definiranom obliku podnose nadležnom Ministarstvu (ili drugoj instituciji koja financira znanstveni projekt).</p> <p><i>Aplikacija treba podržavati statističko izvješćivanje i nadzor nad provedbom: aktivnosti znanstveno istraživačkog projekta, opterećenju i kadrovskim potrebama, realizaciji proračuna projekta, opterećenju znanstvenika, tijeku i rezultatima objavljenih radova (rezultata znanstveno istraživačkog rada), nabavi opreme.</i></p> <p><i>Ključni podaci su: Proračun projekta, Plan opterećenja na znanstvenim projektima, Znanstvenik, Znanstveni projekti, Poslovni partneri (fondovi, poduzeća i visoka učilišta), Oprema.</i></p>
IFN-O Apsolventi studijskog programa; Apsolventi programa cjeloživotnog i stručnog obrazovanja;	<p>Rezultat nastavne djelatnosti visokog učilišta u užem smislu. Studenti koji su upisom na studijski program ili program cjeloživotnog obrazovanja postali privremeni resursi visokog učilišta, nakon završetka studija napuštaju visoko učilište sa stečenim akademskim zvanjem.</p> <p><i>Aplikacija treba podržavati upis studenata na studijski program, upis polaznika stručnih obrazovnih programa obrazovanja, dodjelu prava i obveza svih studenata i drugih korisnika programa obrazovanja, upis studenata na kolegij, planiranje i praćenje izvršenja nastave, evidenciju kolokvija i ispita, formiranje predmeta, pripremu i distribuciju nastavnih materijala, evidenciju uspjeha (ocjena) studenata po kolegijima ili drugim obvezama koje nose ECTS bodove.</i></p> <p><i>Ključni podaci su: Studenti, Studijski programi, Kvalifikacije učenika (državna matura), Predmet, Aktivnosti u nastavi, Nastavni plan i program, Nastavnici, Ispiti, Završni radovi, Mentori, Plan nastavnog opterećenja, Evidencija o realizaciji nastave.</i></p>
IFN-S Izvještaji o provedbi nastavnih programa; Izvještaji o uspjehu studenata; Izvještaji o financiranju nastavne djelatnosti;	<p>Izvještaji o provedbi nastavnih planova i programa fakulteta prema nadređenoj instituciji – Sveučilištu u agregiranom obliku, uključujući i izvješća o nastalim troškovima nastavne djelatnosti.</p> <p>Fakulteti planiraju nastavno opterećenje nastavnika prema broju upisanih studenata na kolegij, predviđenoj satnici nastave i nastavnim oblicima (predavanja, laboratorijske vježbe, seminarska nastava, auditorne vježbe i drug nastavni oblici), kvalifikacijama nastavnika, veličini grupe studenata po obliku nastave. Po potrebi se traži odobrenje za zapošljavanje novih suradnika, ako je to opravdano povećanjem opterećenja zaposlenika. O nastalim troškovima i realizaciji proračuna fakulteta se izvješćuju nadležna tijela.</p> <p><i>Aplikacija treba omogućavati planiranje nastavnih obveza, raspoređivanje</i></p>

	<p><i>nastavnika na kolegije, evidenciju realizirane nastave, izvješćivanje o provedbi nastave.</i></p> <p><i>Ključni podaci su: Studenti, Studijski programi, Predmet, Aktivnosti u nastavi, Nastavni plan i program, Nastavnik, Ispiti, Završni radovi, Mentori, Plan nastavnog opterećenja, Evidencija o realizaciji nastave.</i></p>
<p>IFSR-O</p> <p>Konzultantske usluge na komercijalnim projektima;</p> <p>Proizvodi i usluge;</p> <p>Transfer znanja u privredu;</p>	<p>Rezultat rada na stručnim i komercijalnim projektima: objavljeni rad, knjiga, patent, projekt, inovacija, receptura, metodika, programsko rješenje ili neki drugi proizvod/usluga nastao tijekom projekta. Važan je za evaluaciju stručnog rada. Stručni doprinos treba naći svoju primjenu u privredi (društvu), a aktivnosti transfera znanja mogu biti održavanje seminara, tečajeva, suradnjom s poduzećima na zajedničkim razvojnim projektima i druge aktivnosti.</p> <p><i>Aplikacija mora podržavati evidenciju aktivnosti i rezultata rada članova projektnog tima i praćenje znanstvenih postignuća znanstvenika.</i></p> <p><i>Ključni podaci su: Stručnjak, Stručni projekti, Poslovni partneri (poduzeća i visoka učilišta), Stručni doprinos, Aktivnosti na stručnim projektima, Plan opterećenja na stručnim projektima.</i></p>
<p>IFZR-O</p> <p>Znanstveni doprinos društvu;</p> <p>Inovacije; Transfer znanja u privredu;</p> <p>Objavljeni radovi;</p>	<p>Rezultat znanstveno istraživačkog rada: objavljeni rad, knjiga, patent, projekt, inovacija, receptura, metodika ili neki drugi proizvod/usluga nastao znanstveno istraživačkim radom. Važan je za evaluaciju znanstvenog rada. Znanstveni doprinos treba naći svoju primjenu u privredi (društvu), a aktivnosti transfera znanja mogu biti održavanje seminara, tečajeva, suradnjom s poduzećima na zajedničkim razvojnim projektima i druge aktivnosti.</p> <p><i>Aplikacija mora podržavati evidenciju aktivnosti i rezultata znanstveno istraživačkog rada članova projektnog tima i praćenje znanstvenih postignuća znanstvenika.</i></p> <p><i>Ključni podaci su: Znanstvenik, Znanstveni projekti, Poslovni partneri (poduzeća i visoka učilišta), Znanstveni doprinos, Plan opterećenja na znanstvenim projektima.</i></p>
<p>IFZR-S</p> <p>Objavljeni znanstveni i stručni radovi; Prijave za izbore znanstvenih zvanja; Izvještaj o znanstvenim postignućima;</p>	<p>Znanstvenici evidentiraju objavljene radove i druge rezultate znanstveno istraživačkog rada. Temeljem znanstvenog doprinosa i rezultata rada mogu napredovati u zvanjima. Kada znanstvenik/nastavnik stekne uvjete ili mu istekne vremensko ograničenje zvanja, pokreće se postupak izbora u više zvanje ili reizbora u sadašnje zvanje.</p> <p><i>Aplikacija treba omogućavati evidentiranje objavljenih radova i drugih rezultata znanstveno istraživačkog rada, planiranje, praćenje, odobravanje i potvrđivanje izbora u zvanja kroz različite razine i tijela odlučivanja o napredovanju u zvanjima.</i></p> <p><i>Ključni podaci su: Znanstvenik, Plan opterećenja na znanstvenim projektima, Znanstveni projekti, Znanstveni doprinos, Referencirani radovi, Zvanja, Izbor u zvanje.</i></p>
<p>IO1</p> <p>Smjernice za financiranje;</p> <p>Potrebe i zahtjevi društva, tržišta, poslodavaca i učenika; Modeli</p>	<p>Okruženje visokog učilišta u širem smislu čine građani, Vlada, tijela lokalne samouprave, gospodarski subjekti i akademska zajednica. Oni prema visokom učilištu imaju različita očekivanja i uloge. Studenti žele stjecati akademska znanja i zvanja, poslodavci žele obrazovane stručnjake, gospodarstvo očekuje nova znanstvena postignuća i tehnologije, država očekuje primjenu transfer znanja u gospodarstvo. Pritom svatko od njih na neki način sudjeluje u financiranju visokih</p>

financiranja znanosti i obrazovanja;	<p>učilišta izravno financiranjem određenih djelatnosti ili neizravno kroz poreze. U slučaju visokog učilišta s većinskim financiranjem iz državnog proračuna, Vlada daje smjernice nadležnom Ministarstvu o načinu dodjele sredstava visokim učilištima prema unaprijed određenom modelu financiranja.</p> <p><i>Aplikacija visokog učilišta treba omogućiti evidenciju poslovnih partnera (subjekata iz okruženja) i ugovaranje oblika suradnje ili odnosa s visokim učilištem.</i></p> <p><i>Ključni podaci su: Poslovni parter, Ugovor o suradnji, Oblik suradnje, Kontni plan, Planirane stavke proračuna VU.</i></p>
IO2 Primjena i transfer znanja u društvu; Evaluacija znanstvenih postignuća; Profesionalni i znanstveni utjecaj;	<p>Povratne informacije iz okruženja o kvaliteti studijskih programa, kvaliteti apsolenata, primjeni znanstvenih i stručnih postignuća, lobiranje na profesionalnoj i znanstvenoj razini za učinkovito financiranje i razvoj znanosti.</p> <p><i>Aplikacija treba podržavati prihvati i obradu povratnih informacija iz okruženja (studenata i apsolenata, građanstva, poduzeća, šire znanstvene zajednice) kako bi se unapređivale djelatnosti visokog učilišta. Neki od mogućih oblika povratnih informacija su podaci iz anketa, evidencija citiranih radova i drugi oblici referenciranja objavljenih radova, praćenje objavljenih članaka u javnim glasilima i novinama (engl. pressclipping) i drugo.</i></p> <p><i>Ključni podaci su: Studentske ankete, Nastavni plan i program, Reference radova.</i></p>
IS-M Izveštaj o provedbi sveučilišnog programa; Izveštaj o financiranju sastavnica;	<p>Izveštaji o provedbi nastavnih planova i programa, programima znanstveno istraživačkog i umjetničkog rada koji se provode u sklopu Sveučilišta, te planiranim i stvorenim troškovima koji se mogu financirati iz proračuna nadležnog Ministarstva.</p> <p>Sveučilišta planiraju potrebna sredstva i dostavljaju planove financiranja djelatnosti nadležnom Ministarstvu. Ministarstvo u sklopu svog proračuna odobrava i isplaćuje financijska sredstva. O ostvarenim troškovima Sveučilište redovito izvješćuje Ministarstvo.</p> <p><i>Aplikacija treba omogućiti izravan pristup i korištenje podataka informacijskog sustava Sveučilišta i nadležnog Ministarstva. Cilj je omogućiti unos, obradu, korištenje i pohranu podataka o radu Sveučilišta na mjestu i u realnom vremenu nastanka te korištenje tih podataka u agregiranom obliku od strane nadležnog Ministarstva izravnim pristupom u skladu sa zakonskim ovlastima.</i></p> <p><i>Ključne klase podataka: Kontni plan Sveučilišta, Planirane stavke proračuna Sveučilišta, Realizirane stavke proračuna Sveučilišta.</i></p>
NM-F Natječaj za financiranje znanstvenih projekata; Resursi za znanstveno-istraživački rad; Dopuštenje za zapošljavanje znanstvenih	<p>Nadležno Ministarstvo raspisuje natječaj za financiranje projekata znanstveno istraživačke djelatnosti fakulteta. Fakulteti dostavljaju prijedloge projekata kojima apliciraju za financiranje. Prijedlozi projekata se razmatraju te se odobravaju ako zadovoljavaju kriterijima natječaja. Na znanstveno istraživačkom projektu rade znanstvenici zaposleni na sastavnicama Sveučilišta, a po potrebi fakulteti mogu zatražiti uključivanje mladih istraživača i znanstvenika, što se odobrava kod financijera projekta.</p> <p><i>Aplikacija treba podržavati ugovaranje projekta, planiranje i praćenje realizacije proračuna znanstveno istraživačkog projekta, planiranje i</i></p>

novaka;	<i>praćenje aktivnosti znanstvenih projekata, usuglašavanje opterećenja znanstvenika na projektima, pripremanje prijave projekata na natječaje. Ključni podaci su: Proračun projekta, Plan opterećenja na znanstvenim projektima, Znanstvenik, Znanstveni projekti, Znanstveni doprinos, Poslovni partneri (fondovi, poduzeća i visoka učilišta), Oprema, Referencirani radovi.</i>
NM-S Novčana sredstva za financiranje nastave; Smjernice, pravila i ciljevi;	Nadležno ministarstvo dodjeljuje Sveučilištima određeni iznos prema dogovorenom modelu financiranja djelatnosti. Sveučilište raspodjeljuje doznačena financijska sredstva po sastavnicama te daje smjernice, upute i odluke vezane uz provedbu osnovnih djelatnosti i financiranje istih. <i>Aplikacija treba podržavati planiranje i praćenje realizacije proračuna visokog učilišta u širem smislu, planiranje kadrova i zapošljavanje, praćenje razvoja kompetencija zaposlenika te planiranje i praćenje realizacije nastavnih planova i programa visokog učilišta.</i> <i>Ključni podaci su: Kontni plan, planirane stavke proračuna Sveučilišta, Planirane stavke proračuna fakulteta, Nastavnik, Predmet, Nastavni plan i program.</i>
NS-FN Upisne kvote; Financijska sredstva za nastavnu djelatnost; Evaluacija provedbe nastavnih programa; Akademske kalendar; Resursi za nastavnu djelatnost sastavnice;	Sveučilište odobrava upisne kvote po programima i nastanim planovima svojih sastavnica, definira akademski kalendar, odobrava opskrbu resursima za nastavnu djelatnost (opremu i nastavnike), evaluira i usklađuje nastavne planove i programe po sastavnicama te dodjeljuje financijska sredstva za provedbu nastave. <i>Aplikacija treba omogućiti planiranje, praćenje i usklađivanje proračuna Sveučilišta i sastavnica, odobravanje zapošljavanja novih nastavnika, planiranje i praćenje provedbe nastavne djelatnosti od strane Sveučilišta, planiranje i provedbu objedinjene nabavu opreme i drugih radnih materijalnih resursa za sve sastavnice te nabavu na razini sastavnice, planiranje, usklađivanje i odobravanje nastavnih planova i programa sastavnica.</i> <i>Ključni podaci su: Studenti, Studijski programi, Predmet, Aktivnosti u nastavi, Nastavni plan i program, Nastavnik, Plan nastavnog opterećenja, Evidencija o realizaciji nastave, Kontni plan Sveučilišta, Planirane stavke proračuna Sveučilišta, Realizirane stavke proračuna Sveučilišta, Kontni plan fakulteta, Planirane stavke proračuna fakulteta, Realizirane stavke proračuna fakulteta, Oprema, Akademski kalendar.</i>
NS-FZR Vrednovanje znanstvenih postignuća; Izbori u zvanja; Odobrovanje doktorskih radova; Resursi za znanstveno-istraživački rad;	Sveučilište odobrava opskrbu fakulteta resursima za znanstveno istraživačku djelatnost (opremu i znanstvenike), evaluira znanstvena postignuća, odobrava završne radove (teme i povjerenstva), te prati napredovanja i potvrđuje izbore u znanstvena, nastavna i znanstveno nastavna zvanja. <i>Aplikacija treba omogućiti planiranje, praćenje i usklađivanje proračuna Sveučilišta i sastavnica, odobravanje zapošljavanja novih znanstvenika, planiranje i provedbu objedinjene nabavu opreme i drugih radnih materijalnih resursa za sve sastavnice te nabavu na razini sastavnice, planiranje, odobravanje završnih radova poslijediplomskih studija, te planiranje, praćenje, odobravanje i potvrđivanje izbora u zvanja.</i> <i>Ključni podaci su: Znanstvenik, Proračun projekta, Plan opterećenja na</i>

	<p><i>znanstvenim projektima, Znanstveni projekti, Znanstveni doprinos, Referencirani radovi, Zvanja, Izbor u zvanje, Poslovni partneri (fondovi, poduzeća i visoka učilišta), Oprema, Kontni plan Sveučilišta, Planirane stavke proračuna Sveučilišta, Realizirane stavke proračuna Sveučilišta, Kontni plan fakulteta, Planirane stavke proračuna fakulteta, Realizirane stavke proračuna fakulteta, Akademski kalendar.</i></p>
<p>UO-FN Učenici s i bez položene državne mature; Polaznici programa cjeloživotnog i stručnog obrazovanja;</p>	<p>Ulazni tokovi iz okruženja koji su potrebni za provedbu djelatnosti obrazovanja, odnosno nastave.</p> <p>Pod tim ulaznim resursima smatramo:</p> <ul style="list-style-type: none"> (a) Učenike s i bez položene državne mature – vanjske entitete koji privremeno (za vrijeme trajanja obrazovanja) postaju interni entiteti „studenti“ bez kojih se djelatnost ne bi mogla realizirati. (b) Polaznici programa cjeloživotnog i stručnog obrazovanja - vanjske entitete koji povremeno (svaki put za vrijeme trajanja ciklusa obrazovnog ili stručnog programa obrazovanja) postaju interni entiteti „studenti“ bez kojih se djelatnost ne bi mogla realizirati. <p>Svi se ovi ulazni tokovi posredstvom procesa transformiraju u izlazne tokove opisane pod oznakom IZN-O.</p> <p><i>Aplikacija treba podržavati upis studenata na studijski program, upis polaznika stručnih obrazovnih programa obrazovanja, dodjelu prava i obveza svih studenata i drugih korisnika programa obrazovanja, upis studenata na kolegij, planiranje i praćenje izvršenja nastave, evidenciju kolokvija i ispita, formiranje predmeta, pripremu i distribuciju nastavnih materijala, evidenciju uspjeha (ocjena) studenata po predmetima ili drugim obvezama koje nose ECTS bodove.</i></p> <p><i>Ključni podaci su: Studenti, Studijski programi, Kvalifikacije učenika (državna matura), Predmet, Aktivnosti u nastavi, Nastavni plan i program, Nastavnici, Ispiti, Plan nastavnog opterećenja, Evidencija o realizaciji nastave.</i></p>
<p>UO-FSR Natječajni domaćih i međunarodnih komercijalnih projekata; Partneri na stručnim projektima; Sredstva samofinanciranja;</p>	<p>Ulazni tokovi iz okruženja koji su potrebni za provedbu djelatnosti stručno komercijalnog rada na projektima za gospodarstvo ili općenito, društvo.</p> <p>Pod tim ulaznim resursima smatramo:</p> <ul style="list-style-type: none"> (a) natječaje domaćih i međunarodnih komercijalnih projekata – koji se objavljuju u raznim oblicima i formama te zahtijevaju individualni pristup svakom projektnom natječaju. Prate se u obliku publikacija, internetskih izvora, pozivnih natječaja i drugim oblicima. (b) partnere na stručnim projektima – stručnjake drugih institucija koji mogu sudjelovati u stručnim i komercijalnim projektima institucije; (c) Sredstva samofinanciranja – privatni i drugi izvori vlastitih prihoda visokog učilišta. <p>Svi se ovi ulazni tokovi posredstvom procesa transformiraju u izlazne tokove opisane pod oznakom IZSR-O.</p> <p><i>Aplikacija treba podržavati vođenje evidentiranja podataka o stručnim i komercijalnim projektima, planiranje i raspoređivanje članova projektnih timova po aktivnostima projekta, planiranje, nabavu i raspoređivanje</i></p>

	<p><i>opreme za stručne i komercijalne projekte, evidenciju prihoda i troškova projekata.</i></p> <p><i>Ključni podaci su: Stručni i komercijalni projekti, Aktivnosti SK projekata, Oprema, Stručnjak, Planirane stavke proračuna fakulteta, Realizirane stavke proračuna fakulteta.</i></p>
<p>UO-FZR</p> <p>Stručna literatura;</p> <p>Oprema za znanstvenu djelatnost;</p> <p>Znanstveni novaci;</p> <p>Partneri na ZI projektima;</p> <p>Sredstva samofinanciranja;</p>	<p>Ulazni tokovi iz okruženja koji su potrebni za provedbu djelatnosti znanstveno istraživačkog rada.</p> <p>Pod tim ulaznim tokovima smatramo:</p> <p>(a) stručnu literaturu – koja može biti u obliku publikacija, internetskih izvora, istraživačkih studija i drugim oblicima;</p> <p>(b) opremu za znanstvenu djelatnost – pod ovime se podrazumijeva oprema za laboratorijska istraživanja, ICT oprema i drugi materijalni resursi;</p> <p>(c) znanstvene novake - stručnjake koji će se baviti znanstveno istraživačkim radom i imaju potencijal nakon toga postati znanstvenik;</p> <p>(d) Partneri na ZI projektima – stručnjake drugih institucija koji mogu sudjelovati u znanstvenim projektima institucije;</p> <p>(e) Sredstva samofinanciranja – privatni i drugi izvori vlastitih prihoda visokog učilišta.</p> <p>Svi se ovi ulazni tokovi posredstvom procesa znanstveno istraživačkog rada transformiraju u izlazne tokove opisane pod oznakom IZZR-O.</p> <p><i>Aplikacija treba podržavati vođenje evidencije korištenja stručne literature u knjižnici visokog učilišta, evidentiranje podataka o znanstvenim projektima, planiranje aktivnosti i raspoređivanje članova projektnih timova po aktivnostima projekta, planiranje, nabavu i raspoređivanje opreme za znanstveno istraživački rad, evidenciju znanstvenika partnerskih visokih učilišta, evidenciju prihoda i troškova projekata.</i></p> <p><i>Ključni podaci su: Publikacije, Oprema, Znanstvenik, Poslovni partneri (druga visoka učilišta), Znanstveni projekti, Aktivnosti na projektima, Planirane stavke proračuna fakulteta, Realizirane stavke proračuna fakulteta.</i></p>

Genetičkom definicijom informacijskog sustava su identificirani osnovni tokovi podataka, naloga, izvješća i drugih podatkovnih resursa u visokim učilištima te osnovni funkcionalni zahtjevi na informacijski sustav koji treba podržavati korištenje tih tokova. Zaključak analize strukture sustava i okruženja visokih učilišta jest činjenica da su visoka učilišta zbog svog specifičnog područja djelovanja složeni sustavi kod kojih je zbog jedinstvene organizacijske složenosti identificirana potreba za procesnom horizontalnom i vertikalnom integracijom u izvedbi poslova ključnih djelatnosti: nastavne, znanstveno istraživačke i stručne. Informacijski sustav koji treba podržavati rad visokih učilišta stoga treba omogućiti interoperabilnost informacijskih podsustava

svih sastavnica Sveučilišta (visokog učilišta u širem smislu) na način da je omogućena provedba poslova u cjelini bez prekida u postupku, bez dupliciranja zapisa i nepotrebnih koraka u postupku, bez nepotrebnih kašnjenja i na transparentan način prema korisnicima rezultata postupaka. Da bi se to ostvarilo treba razlikovati tehničke preduvjete i mogućnosti, od onih koji su vezani uz podatke i procese visokih učilišta. Nužno je u tom kontekstu razlikovati informatičku infrastrukturu kao skup hardverske i softverske opreme koja omogućava tehničku kompatibilnost i interoperabilnost informacijskih sustava, od informacijske infrastrukture koja obuhvaća skup kataloških (matičnih) podataka i postupaka obrade tih podataka namijenjenih procesnoj i podatkovnoj kompatibilnosti i interoperabilnosti. Funkcionalni zahtjevi na informacijski sustav koji su identificirani u ovom poglavlju trebaju biti uzeti u obzir kod projektiranja informacijskog sustava visokih učilišta.

3. Model poslovnih i akademskih procesa visokih učilišta

Kao što je rečeno u prvom potpoglavlju, temeljne djelatnosti visokih učilišta su (1) rad u nastavi, (2) znanstveno istraživački rad i (3) stručni rad. Ove djelatnosti su međusobno povezane rezultatima provedbe djelatnosti, na način da se rezultati znanstveno istraživačkog rada prenose u društvo i kasniju primjenu znanstvenih postignuća, kroz nastavu i obrazovanje, ali isto tako se primjenjuju ciljano u gospodarstvu kroz stručno komercijalne projekte. Rezultati stručno komercijalnih projekata su poticaj i potvrda znanstveno istraživačkog rada, te dopuna primjeni teoretskih znanja u nastavnom radu. Temeljne djelatnosti se provode izvedbom poslovnih procesa, stoga najprije treba primjenom prikladnih metoda identificirati poslovne procese.

Dekompozicijom glavnih triju djelatnosti na poslove i analizom pravnih akata i pravilnika koji uređuju područje djelovanja, izrađen je popis osnovnih prepoznatih procesa visokih učilišta. Prepoznati poslovni i akademski procesi visokih učilišta su navedeni u tablici 3.1., a poredani su abecedno.

Tablica 3.1.: Popis poslovnih i akademskih procesa visokih učilišta

Naziv procesa	Sažeti opis procesa
Evidentirati i provoditi plaćanja	Nadležna osoba zadužena za evidenciju i provedbu financijskih transakcija evidentira podatke o planiranim transakcijama. Provjerava se ispravnost podatka na platnim nalogima, odobravaju se isplate te provode nalozi. Podaci o provedenim transakcijama se usklađuju s podacima o proknjiženim poslovnim događajima.
Formirati predmet NPP	Na temelju prijedloga promjena nastavnog plana i programa (skraćeno NPP) i/ili primjenom novih temeljnih ili primijenjenih znanja nastavnici formiraju nove ili postojeće predmete NPP-a. Podaci o predmetima se unose u IS, a na temelju tih podataka se planiraju nastavna opterećenja nastavnika te daju dopusnice od strane nadležnih tijela upravljanja (npr. resornog ministarstva). Kvaliteta predmeta utječe na sliku visokog učilišta u okruženju te utječe na ocjenu društvenog doprinosa visokog učilišta.
Izdavati javne isprave	Visoko učilište sukladno dopusnici za studij može izdavati javne isprave kojima se dokazuje status studenta na studijskom programu. Specifična vrsta javne isprave koje izdaje visoko učilište je uvjerenje o završetku studijskog programa.
Izdavati rješenja i izvješća	Pokretanjem postupka izmjene ugovorenih prava i obveza mora biti izvršen propisani postupak rješavanje zahtjeva promjene obveze ili prava. Postupak, rješenje postupka i izvješće o provedenim postupcima moraju biti popraćeni odgovarajućom dokumentacijom koja se u elektroničkom obliku čuva u IS-u u potrebnom formatu.

Izlagati na stručnim skupovima	Stručnjaci visokog učilišta potvrđuju stečena znanja kroz rad na stručnim i komercijalnim projektima. Njihova je moralna obveza sudjelovati na stručnim skupovima i ukazivati na pozitivne ili negativne primjere iz prakse. Izvrsnost u stručnom radu je jedna od mjera percepcije društvenog doprinosa visokog učilišta.
Izlagati na znanstvenim skupovima	Znanstvenici visokog učilišta razvijaju nova znanja kroz znanstveno istraživački rad na projektima. Njihova je moralna dužnost i obveza širiti nove spoznaje i ukazivati na pozitivne ili negativne primjere iz istraživačkog rada. Izvrsnost u znanstvenom radu je jedna od mjera percepcije društvenog doprinosa visokog učilišta.
Izraditi proizvod/uslugu	Izraditi proizvod/ uslugu je proces koji obuhvaća inovativne aktivnosti rada na stručnim i komercijalnim projektima. Opseg i oblici aktivnosti rad na projektu ovise o području rada. Aktivnosti rada na projektu se planiraju u IS-u kao jedan od oblika opterećenja zaposlenika te se prati realizacija radi obračuna utrošenih resursa i daljnjeg planiranja opterećenja.
Izraditi raspored	Raspored se izrađuje na temelju podataka o broju upisanih studenata na predmet, podacima o raspoloživim lokacijama (dvoranama, laboratorijima isl.), planu opterećenja zaposlenika, raspoloživoj opremi i akademskom kalendaru. Raspored predstavlja plan aktivnosti i zauzeća resursa u obrazovnom ciklusu.
Izvješćivati o akademskim postignućima	Na temelju podataka o realizaciji opterećenja zaposlenika u nastavnoj i znanstvenoj djelatnosti se generiraju izvješća o akademskim postignućima zaposlenika VU.
Izvješćivati o financijskom poslovanju	Na temelju podataka o realizaciji planiranog proračuna visoko učilište može izvješćivati nadležne institucije o financijskom poslovanju. Za interno izvješćivanje (prema resornom ministarstvu ili sveučilištu) treba omogućiti pristup podacima s aplikacijama za čitanje postojećih podataka u unaprijed definiranoj formi izvješća, što smanjuje potrebu za generiranjem ad-hoc izvješća.
Izvješćivati o tijeku i rezultatima SK projekta	Rezultati rada na stručnim projektima se objavljuju kao stručni radovi ili izlažu na stručnim skupovima. Kvaliteta stručnog rada pokazuje vrijednost novog primijenjenog znanja koje se generira u projektima. Visoko učilište prati i nadzire kvalitetu i brojnost stručnih radova radi praćenja učinkovitosti stručnjaka i ocjene društvenog doprinosa kroz stručni rad.
Izvješćivati o tijeku i rezultatima ZI projekta	Rezultati znanstveno istraživačkog rada se objavljuju kao znanstveni radovi ili izlažu na znanstvenim skupovima. Visoko učilište prati i nadzire kvalitetu i brojnost znanstvenih radova te o tome izvješćuje nadležna tijela unutar i izvan visokog učilišta radi praćenja učinkovitosti znanstvenika i ocjene društvenog doprinosa kroz znanstveno istraživački rad.
Izvoditi nastavu	S početkom obrazovnog ciklusa nastavnici počinju izvoditi planirane nastavne aktivnosti prema rasporedu nastave. Realizirana nastava se evidentira u IS-a. Za svaki predmet, nastavnik definira metode i modele praćenja uspjeha studenta tijekom izvođenja nastave te načine i rokove za polaganje ispita u redovitim ispitnim rokovima.
Knjižiti poslovne događaje	Pod knjiženjem poslovnih događaja se podrazumijeva provjera ispravnosti podataka na izvornim dokumentima (npr. računima), evidentiranje poslovnog događaja opisanog dokumentom te knjiženje troška ili prihoda prema kontnom planu. Na temelju unesenih podataka se obračunavaju i fakturiraju nastali troškovi.

Kontrolirati provedbu NPP	Nadležna osoba (prodekan za nastavu) i druga upravljačka tijela kontroliraju provedbu NPP-a. Kontrola se provodi na temelju rasporeda koji predstavlja planirano vrijeme, lokacije i izvršitelje, te podataka o stvarnoj realizaciji nastave. Podaci o značajnim odstupanjima plana i realizacije se upućuju na predlaganje promjena NPP-a.
Kreirati i održavati online kataloge	Visoko učilište može ustrojiti knjižnicu namijenjenu vlastitim studentima i zaposlenicima te drugim osobama izvan visokog učilišta. Ako je uspostavljena, knjižnica mora imati katalog građe, koji može biti formiran kao online katalog za evidenciju ne samo fizičke građe knjižnice, već i e-znanstvenih radova. Kvaliteta knjižnične građe može također biti jedna od mjera percepcije društvenog doprinosa visokog učilišta.
Mentorirati studenta	Nastavnik s definiranim kvalifikacijama može biti mentor izrade završnog, diplomskog, specijalističkog ili doktorskog rada. Načini mentorskog rada mogu za različite studije imati različite provedbene oblike.
Nabavljati knjige i drugu k-građu	Ako je uspostavljena, knjižnica mora imati nabavljati knjižničnu građu. Knjižnična građa može biti fizička građa knjižnice, ali i e-znanstvenih radova, online publikacije, e-kopije ili fizičke kopije posuđene građe iz drugih knjižnica i drugo. Kvaliteta knjižnične građe može također biti jedna od mjera percepcije društvenog doprinosa visokog učilišta.
Nabavljati opremu	Zaposlenici visokog učilišta mogu zatražiti nabavu infrastrukturne opreme za rad. Na temelju stavki specifikacija generira se dokumentacija za nabavu. Neprivatna visoka učilišta su u sustavu javne nabave, stoga je postupak nabave reguliran Zakonu o javnoj nabavi.
Nadzirati izvršenje proračuna	Nadležna osoba uprave visokog učilišta odobrava obračune troškova poslovanja, prati promete po bankovnim računima VU, te prati izvršenje proračuna po planiranim i realiziranim stavkama.
Nadzirati provedbu investicijskih projekata	Nadležna osoba uprave visokog učilišta nadzire provedbu investicijskih projekata, koji su ugovoreni s vanjskim izvođačem radova te daje smjernice i upute za planiranje budućih projekata, odnosno za korigiranje postojećih.
Napredovati u zvanju	Proces napredovati u zvanju je složen proces suradnje učesnika iz hijerarhijski i funkcionalno različitih organizacija te zato predstavlja tipičan primjer procesa visokog učilišta koji zahtijeva interoperabilnost. Proces obuhvaća aktivnosti vrednovanja akademskih postignuća znanstvenika/nastavnika a detaljno je modeliran u 8. poglavlju rada.
Objavljivati stručne radove	Stručnjaci visokog učilišta razvijaju nova znanja kroz rad na stručnim i komercijalnim projektima te rezultate objavljuju u obliku stručnih radova. Kvaliteta stručnih radova je jedna od mjera percepcije društvenog doprinosa stručnjaka.
Objavljivati znanstvene radove	Znanstvenici visokog učilišta razvijaju nova znanja kroz znanstveno istraživački rad na projektima te rezultate objavljuju u obliku znanstvenih radova. Znanstveni radovi su jedna od mjera znanstveno istraživačke učinkovitosti unutar visokog učilišta i jedna od mjera percepcije društvenog doprinosa znanstvenika.
Obračunati i fakturirati	Proces obuhvaća aktivnosti obračuna evidentiranih poslovnih događaja i planiranih priljeva i odljeva sredstava te fakturiranje. Obračuni se kasnije provjeravaju te se odobrava njihova provedba platnim nalogima.
Ocjenjivati završne radove	Nastavnik s definiranim kvalifikacijama može biti član povjerenstva za ocjenu i/ili obranu završnog, diplomskog, specijalističkog ili doktorskog rada. Način ocjenjivanja radova su propisane za svaki studij.

Odobriti temu i organizirati obranu	Nastavnik s definiranim kvalifikacijama može biti voditelj izrade završnog, diplomskog, specijalističkog ili doktorskog rada. Ovisno o vrsti studija i/ili preferencijama i kvalifikacijama nastavnika, definiraju se teme radova. Odobrene teme se evidentiraju u IS-a.
Održavati ICT opremu	Proces obuhvaća aktivnosti preventivnog, redovitog, korektivnog održavanja informacijsko komunikacijske infrastrukturne opreme potrebne za rad zaposlenika visokog učilišta.
Održavati informacijske sustave VU	Proces obuhvaća aktivnosti održavanja funkcionalnosti informacijsko komunikacijske infrastrukturne opreme potrebne za rad zaposlenika visokog učilišta.
Održavati ispite	Nakon izvedbe nastave na predmetu nastavnik s odgovarajućim ovlaštenjima održava ispitne rokove. Rezultati ispitnih rokova se evidentiraju u IS.
Održavati tečajeve i seminare	Zaposlenici VU mogu organizirati i održavati tečajeve i seminare za različite kategorije potencijalnih korisnika iz svih kategorija društva. Ovaj proces je značajan zbog prijenosa novog primijenjenog znanja i popularizacije struke te se može ocjenjivati kao stručni doprinos visokog učilišta.
Organizirati ALUMNI udrugu	Proces organiziranja ALUMNI udruge obuhvaća razne aktivnosti održavanja i jačanja poslovnih, znanstvenih, stručnih, donatorskih, kolegijalnih i drugih veza sa studentima i drugim prijateljima visokog učilišta.
Organizirati praktikum	Proces obuhvaća aktivnosti organiziranja, provedbe i nadzora primjene stečenih znanja u stvarnim stručnim sredinama. Kada student dostavi ovjereni dokaz provedenog praktikuma, evidentira se potvrda zaključenja ove NPP-om propisane aktivnosti u sklopu obrazovanja.
Organizirati studentska natjecanja	Radi provjere sposobnosti studenata da primijene stečena temeljna i primijenjena znanja, nastavnici organiziraju i sudjeluju kao mentori u studentskim natjecanjima. Rezultati natjecanja utječu na sliku visokog učilišta u okruženju te utječe na interes potencijalnih aplikanata za upis.
Organizirati znanstvene skupove	Visoko učilište može organizirati znanstvene skupove te na taj način doprinijeti prijenosu rezultata znanstveno istraživačkog rada u gospodarstvo. Ovaj proces je značajan zbog prijenosa novog temeljnog znanja i popularizacije znanosti te se može ocjenjivati kao znanstveni doprinos visokog učilišta.
Planirati akademski razvoj	Planiranje akademskog razvoja se provodi prema planu opterećenja zaposlenika. Na temelju evidencije zaposlenika i poslovnih planova definira se plan kadrova koji će osigurati potrebnu stručnu jezgru za ostvarenje zadanih ciljeva. Uzimajući u obzir potrebe i raspoložive kadrove, planiraju se zapošljavanja, specijalizacije i obrazovanje zaposlenika uključene u akademsku djelatnost. Akademski razvoj kadrova je jedna od mjera percepcije društvenog doprinosa visokog učilišta.
Planirati poslovanje VU	Planiranje provedbe poslovnih ciljeva se temelji na poslovnim planovima organizacije i rezultira provedbenim planovima za određene poslovne ciljeve (kadrovski plan, plan potrebnih sredstava). Operacionalizacija poslovnih planova se provodi kroz odluke fakultetskog vijeća i Uprave visokog učilišta te se reflektira i u planiranom proračunu.
Planirati proračun	Planiranje proračuna po stavkama se provodi na način da osigura provedba upravljačkih poslovnih odluka Uprave i fakultetskog vijeća, da se omogući izvođenje osnovnih djelatnosti visokog učilišta te stvore financijske rezerve za likvidnost poslovanja. Proračun visokog učilišta se u RH usklađuje s proračunom nadležnog sveučilišta a u okviru raspoloživih sredstava odobrenih od strane resornog ministarstva.

Planirati ZI projekt	Znanstvenici planiraju znanstveno istraživačke projekte unutar područja od interesa. Proces planiranja obuhvaća okvirno planiranje aktivnosti projekta, suradnika na projektu i troškova projekta, a završava izradom plana projekta u formatu koji je zadan unaprijed od strane potencijalnih izvora financiranja.
Posuđivati knjige i k-građu	Proces obuhvaća karakteristične poslove vezane uz posudbu knjižničnih materijala, knjiga, radova i druge građe.
Pratiti javne natječaje SK projekata	Stručnjaci sa znanjima primjenjivim u gospodarstvu i drugim realnim područjima primjene stručnih znanja, prate natječaje za rad na projektima stručnog područja od interesa.
Pratiti realizaciju opterećenja	Upravljačko tijelo prati realizaciju opterećenja zaposlenika (npr. katedra, mentori asistenata). Praćenje se provodi na temelju rasporeda koji predstavlja planirano vrijeme, lokacije i izvršitelje, te podataka o stvarnoj realizaciji nastave. Podaci o planu i realizacije opterećenja se koriste za usklađivanje i raspoređivanje opterećenja zaposlenika po djelatnostima visokog učilišta, te za obračun troškova rada zaposlenika.
Predlagati promjene NPP	Nakon provedbe jednog ili više ciklusa nastave, analizira se NPP, uspoređuju se podaci o planiranoj i realiziranoj razini opterećenja nastavnika te se po potrebi nerealne raspoložive satnice predlažu promjene NPP-a. Prijedlozi promjena NPP mogu biti uzrokovani i drugim poticajima, kao što su interne analize kvalitete predmeta ili eksterna uspoređivanja s relevantnim i usporedivim nastavnim planovima drugih visokih učilišta. Kvaliteta NPP-a utječe na sliku visokog učilišta u okruženju te utječe na ocjenu društvenog doprinosa visokog učilišta.
Prezentirati klijentu	Prezentiranje klijentu se odnosi na prezentaciju rezultata rada na SK projektu. Proces predstavlja kontrolnu točku u radu na projektu, jer će ovisno o kvaliteti rješenja ili projekt moći biti završen primjenom rješenja u praksi ili trebati doraditi projekt (što podrazumijeva novo radno opterećenje).
Prijaviti SK projekt na natječaj	Praćenjem natječaja za stručne i komercijalne projekte stručnjaci odabiru projekte za koje žele aplicirati. Prijava SK projekta se provodi na način definiran natječajem i zahtjevima investitora te ovaj proces ne može biti značajno podržan ICT-om.
Prijaviti ZI projekt na natječaj	Planirani znanstveno istraživački projekt se prijavljuje na natječaj za financiranje znanstvenih projekata. Način i potrebna dokumentacija ovise o investitoru i te ovaj proces ne može biti značajno podržan ICT-om.
Pripremati investicijske projekte	Uprava visokog učilišta planira investicijske projekte, traži suglasnost fakultetskog vijeća te pokreće pripremu dokumentacije investicijskog projekta. Investicijski projekti su predviđeni proračunom visokog učilišta koji se realizira sredstvima državnog proračuna te stoga moraju biti provedeni u skladu sa Zakonom o javnoj nabavi.
Pripremati nastavne materijale	Nastavnici kreiraju i ažuriraju nastavne materijale predmeta. Gotovi e-nastavni materijali se objavljuju pomoću odgovarajućeg alata za e-učenje i time čine dostupnim studentima na kolegiju.
Promovirati apsolvante	Promocija apsolvenata se provodi na temelju uvjerenja o završetku studijskog programa. Završetkom studijskog programa apsolvant stječe prava i obveze vezane uz stečeno zvanje.

Provesti upisnu proceduru	Pristigle prijave potencijalnih studenata se obrađuju te se provodi upisna procedura za odabir studenata. Upisna procedura može obuhvaćati različit e postupke bodovanja i rangiranja aplikanata za upis od preuzimanja podataka s državne mature do dodatnog testiranja određenih sposobnosti aplikanata.
Provjeriti preduvjete predmeta	U skladu s rokovima za upisni postupak u obrazovnom ciklusu (npr. semestru) student odabire predmete koje želi ili treba odabrati prema NPP-u. Odabir predmeta se obavlja pomoću prijave i identifikacije studenta u IS te odgovarajuće aplikacije modula za potporu procesa nastavne djelatnosti. Provjera preduvjeta predmeta je automatizirana jer se provodi na temelju podataka u NPP-u, matičnih i transakcijskih podataka o studentu (npr. pod transakcijskim podacima studenta podrazumijevamo prethodno odabrane, odslušane i/ili položene predmete). Ako je odabir predmeta valjan, onda se studenta upisuje na odabrane predmete. Ako odabir predmeta nije valjan, onda se studenta upućuje na izmjene odabira.
Provoditi istraživanja	Znanstvenici rade na znanstveno istraživačkim projektima s ugovorenim financiranjem. Opseg rada na projektu je definiran prijavom ZI projekta. Rezultati istraživanja se koriste dalje za znanstveno istraživački rad i razvoj prototipova i pilot projekata. Kvaliteta znanstveno istraživačkog rada je jedna od mjera percepcije društvenog doprinosa visokog učilišta.
Provoditi promotivne akcije	Proces obuhvaća različite oblike promocije visokog učilišta, studijskih programa, kvalitete izvođenja prvenstveno nastavne, ali i znanstvene i stručne djelatnosti visokog učilišta.
Provoditi upravno-pravne poslove	Pokretanjem postupka izmjene ugovorenih prava i obveza mora biti izvršen propisani upravni ili neupravni postupak rješavanja zahtjeva ili primjene odluke. Postupak, rješenje postupka i izvješće o provedenim postupcima moraju biti popraćeni odgovarajućom dokumentacijom koja se u elektroničkom obliku čuva u IS-u u potrebnom formatu. Proces obuhvaća i sve pravne poslove prema okruženju visokog učilišta u što spadaju aktivnosti vezane uz ishodenje dopusnica, suglasnosti i odobrenja od nadređenih tijela upravljanja.
Raditi na SK projektu	Rad na SK projektu podrazumijeva primjenu stručnih metoda primjerenih području i problemskoj domeni. Primjena ICT u provedbi ovog procese je ograničena na evidenciju podataka tijekom rada i rezultata.
Raditi na ZI projektu	Rad na ZI projektu podrazumijeva primjenu znanstveno istraživačkih metoda primjerenih znanstveno području. Primjena ICT u provedbi ovog procese je ograničena na evidenciju podataka tijekom rada i rezultata.
Raspisati natječaj za upis	Raspisivanje natječaja za upis na studijski program se provodi prema izdanoj dopusnici i odobrenim upisnim kvotama. Upisni rokovi se definiraju za svaki studij, a sukladno rokovima koji su zadani iz okruženja ili prema odluci nadležnog internog tijela upravljanja. Interes potencijalnih studenata je jedna od mjera percepcije kvalitete visokog učilišta u društvu.
Raspoređivati i ugrađivati ICT opremu	Proces obuhvaća aktivnosti uspostavljanja funkcionalnosti i tehničke ispravnosti informacijsko komunikacijske infrastrukturne opreme potrebne za rad zaposlenika visokog učilišta.
Raspoređivati opterećenje zaposlenika	Raspoređivanje opterećenja se provodi za svakog zaposlenika prema kvalifikacijama i afinitetu prema različitim djelatnostima (nastava, znanost, struka). Opterećenja se usklađuju s planom akademskog razvoja i potreba za provedbom NPP-a.

Razvijati i uvoditi aplikacije za VU	Proces obuhvaća redovne aktivnosti nadogradnje postojećeg informacijskog sustava visokog učilišta kao što su implementacije tekućih odluka i poslovnih zahtjeva.
Razvijati prototipove i pilot projekte	Razvoj prototipova i pilot projekata se obavlja na temelju rezultata istraživanja i znanstvenog rada. Razvijeni prototipovi, usluge, postupci i drugi rezultati se primjenjuju u praksi.
Recenzirati radove i projekte	Ako visoko učilište organizira znanstveni skup u sklopu kojeg će se objaviti prezentirani i/ ili prihvaćeni radovi, onda mora biti omogućeno vrednovanje pristiglih prijedloga znanstvenih radova. U praksi postoje kvalitetni informacijski podsustavi za potporu cjelovitog postupka organizacije i provedbe online recenzentskih postupaka koji se mogu povezati sa ERP sustavima.
Upisati studenta na kolegij	Ako je student izvršio valjan odabir predmeta, onda se studenta upisuje na kolegij. Pod kolegijem se smatra privremeni skup studenta, nastavnika na predmeta u jedinici akademskog kalendara.
Upisati studenta na studij	Upis studenta na studij se izvršava na temelju rangiranih prijava aplikanata, a rezultira evidentiranjem podataka o studentu i upisanom studiju te prava i obveza koje iz novonastalog odnosa proizlaze.
Upravljeti korisničkim računima	Upisani studenti dobivaju korisnički račun koji im omogućava pristup informacijskom sustavu, identifikaciju u sveučilišnim informacijskim podsustavima namijenjenim studentima i drugim potencijalnim e-uslugama vezanim uz visoko obrazovanje.
Upravljeti VU	<i>Složeni proces koji obuhvaća niz menadžerskih potprocesa te se treba dodatno detaljnije modelirati. Proces je dodan u popis procesa sukladno preporuci Europske komisije za standardizaciju⁸ da se u model procesa dodaju i menadžerski procesi. Menadžerski procesi nisu operativne naravi, ne generiraju standardizirane podatke koji bi se mogli strukturirano voditi u bazi podataka ERP sustava, već obuhvaćaju niz intuitivnih i kreativnih aktivnosti i postupaka. Upravljeti VU podrazumijeva: Definirati razvojne ciljeve visokog učilišta, Definirati strategije ostvarenja vizije i razvojnih ciljeva, Komunicirati strategije kroz VU, Odlučivati, Pratiti ostvarenje strategija poslovanja, Analizirati uspješnost poslovanja, Upravljeti odnosima s okruženjem.</i>
Urudžbirati i obrađivati dokumentaciju	Upisom na studij student stječe prava i obveze. Prava i obveze su vezane uz odnos studenta s institucijom visokog obrazovanja proizlaze. Kod odstupanja od mogućnosti realizacije prava i obveza svaka strana ima mogućnost pokretanja postupka izmjene obveza ili prava. Pokretanje postupka izmjene ugovorenih prava i obveza mora biti popraćeno odgovarajućom dokumentacijom koja se u elektroničkom obliku čuva u IS-u u odgovarajućem formatu.

Nad prepoznatim procesima treba provesti tri provjere kompletnosti popisa procesa:

1. s obzirom na značaj procesa u upravljanju resursima poslovanja
2. s obzirom na životni ciklus resursa
3. s obzirom na značaj procesa za ostvarenje misije

U nastavku su opisane provedene analize kompletnosti popisa procesa visokih učilišta.

⁸ European committee for standardization, <http://www.cen.eu/>

3.1. Analiza kompletnosti popisa procesa s obzirom na značaj procesa u upravljanju resursima poslovanja

Analiza kompletnosti popisa procesa je najprije provedena i s obzirom na značaj procesa u upravljanju resursima poslovanja. Prema Strahonji [84], procesi upravljanja resursima poslovanja se odnose na planiranje, upravljanje, izvršenje, obračun i kontrolu. Prepoznati procesi visokih učilišta su na u tablici 3.2. razvrstani u navedenih 5 kategorija procesa (planiranje, upravljanje, izvršenje, obračun, kontrola) s obzirom na 5 klasa resursa: resursi vezani uz 1. nastavu, 2. znanost, 3. struku, 4. infrastrukturu i poslovanje ili 5. društveni doprinos visokog učilišta. Za svaku kategoriju resursa također je potrebno provjeriti jesu li identificirani procesi svake kategorije procesa i svake vrste resursa. Grupiranje procesa je provedeno u tablici 3.2.

Tablica 3.2.: Grupiranje poslovnih i akademskih procesa visokih učilišta s obzirom na značaj u upravljanju resursima poslovanja

Resursi vezani uz nastavu	
Formirati predmete NPP	PLANIRANJE
Pripremati nastavne materijale	
Provesti upisnu proceduru	
Provoditi promotivne akcije	
Raspisati natječaj za upis	
Planirati akademski razvoj	
Raspoređivati opterećenje zaposlenika	UPRAVLJANJE
Izraditi raspored	
Organizirati studentska natjecanja	
Provoditi upravno-pravne poslove	
Upisati studenta na kolegij	
Upisati studenta na studij	
Ocjenjivati završne radove	IZVRŠENJE
Izdavati javne isprave	
Izdavati rješenja i izvješća	
Izvoditi nastavu	
Mentorirati studenta	
Odobriti temu i organizirati obranu	
Održavati ispite	
Organizirati praktikum	
Promovirati apsolvente	
Provjeriti preduvjete predmeta	
Upravlјati korisničkim računima	
Pratiti realizaciju opterećenja	
Izvješćivati o akademskim postignućima	
Kontrolirati provedbu NPP	OBRAČUN
Predlagati promjene NPP	
	KONTROLA

Resursi vezani uz struku	
Pratiti javne natječaje SK projekata	PLANIRANJE
Prijaviti SK projekt na natječaj	UPRAVLJANJE
Raspoređivati opterećenje zaposlenika	
Izlagati na stručnim skupovima	IZVRŠENJE
Izraditi proizvod/uslugu	
Objavljivati stručne radove	
Raditi na SK projektu	
Razvijati prototipove i pilot projekte	
Pratiti realizaciju opterećenja	OBRAČUN
Izvešćivati o tijeku i rezultatima SK projekta	KONTROLA
Prezentirati klijentu	
Resursi vezani uz znanost	
Planirati akademski razvoj	PLANIRANJE
Planirati ZI projekt	
Napredovati u zvanju	UPRAVLJANJE
Prijaviti ZI projekt na natječaj	
Raspoređivati opterećenje zaposlenika	IZVRŠENJE
Provoditi istraživanja	
Izlagati na znanstvenim skupovima	
Objavljivati znanstvene radove	
Raditi na ZI projektu	
Recenzirati radove i projekte	OBRAČUN
Pratiti realizaciju opterećenja	
Izvešćivati o akademskim postignućima	
Izvešćivati o tijeku i rezultatima ZI projekta	
Organizirati znanstvene skupove	
Resursi vezani uz poslovanje i infrastrukturu	
Planirati poslovanje VU	PLANIRANJE
Planirati proračun	
Upravlјati VU	UPRAVLJANJE
Nadzirati provedbu investicijskih projekata	
Održavati informacijske sustave VU	IZVRŠENJE
Pripremati investicijske projekte	
Evidentirati i provoditi plaćanja	
Knjižiti poslovne događaje	
Nabavljati opremu	
Održavati ICT opremu	
Raspoređivati i ugrađivati ICT opremu	
Razvijati i uvoditi aplikacije za VU	
Urudžbirati i obrađivati dokumentaciju	
Obračunati i fakturirati	
Pratiti realizaciju opterećenja	OBRAČUN
Nadzirati izvršenje proračuna	KONTROLA
Izvešćivati o financijskom poslovanju	
Resursi vezani uz društveni doprinos	
Planirati akademski razvoj	PLANIRANJE
Organizirati studentska natjecanja	UPRAVLJANJE
Predlagati promjene NPP	
Formirati predmet NPP	

Izlagati na stručnim skupovima	IZVRŠENJE
Izlagati na znanstvenim skupovima	
Kreirati i održavati online kataloge	
Nabavljati knjige i drugu k-građu	
Objavljivati stručne radove	
Objavljivati znanstvene radove	
Održavati tečajeve i seminare	
Organizirati ALUMNI udrugu	
Posuđivati knjige i k-građu	
Provoditi istraživanja	
Promovirati apsolvante	OBRAČUN
Raspisati natječaj za upis	KONTROLA

Analiza je pokazala da su identificirani procesi svake kategorije za svaku vrstu resursa, što znači da je ova provjera kompletnosti popisa procesa zadovoljena te da se može provesti sljedeća provjera koja je orijentirana na pojedinačne ključne resurse.

3.2. Analiza kompletnosti popisa procesa s obzirom na životni ciklus resursa

Kako bi se mogla provesti analiza kompletnosti popisa procesa s obzirom na životni ciklus osnovnih resursa, potrebno je definirati osnovne resurse visokih učilišta. Osnovni ili ključni resursi su objekti nad kojima se izvodi neki posao, aktivnost ili operacija, korištenjem se troši ili mijenja svoj oblik, pripada organizaciji, može izazivati trošak, a bez njega se djelatnost ne bi mogla odvijati. Pod resursima ćemo smatrati i druge entitete od interesa koji su stalni u sustavu (npr. zaposlenici) ili se samo privremeno uključuju u djelovanje organizacijskog sustava (npr. studenti). Kako se u organizacijama koristi puno različitih resursa, ovdje ćemo se baviti samo onim resursima koji su karakteristični i ključni za temeljne djelatnosti visokih učilišta. Stoga ćemo pod resursima visokih učilišta razmatrati resurse opisane u poglavlju 2.4: Student, Nastavnik, Znanstvenik, Stručnjak, Nastavni plan i program, Predmet, Znanstveni doprinos, Stručni doprinos, Tehnička infrastruktura i oprema, te Novac.

Za svaki resurs treba u popisu procesa pronaći procese koji omogućavaju transformaciju resursa od njegovog ulaznog oblika do izlaznog, npr. treba provjeriti postoji li u popisu procesa slijed procesa koji omogućava da student postane apsolvent. U tom kontekstu se

može reći da analizu životnog ciklusa resursa treba shvatiti kao jedan prolaz kroz slijed procesa koji omogućavaju da se resurs transformira u željeni oblik, odnosno da se radi o jednoj iteraciji slijeda procesa koja završava određenim stanjem sustava.

Slijed procesa obuhvaća procese transformacije resursa kroz 4 faze životnog ciklusa resursa (slika 3.1.):

1. faza: planiranje
2. faza: prikupljanje
3. faza: korištenje,
4. faza: obnavljanje ili nestajanje.

Prolaskom kroz faze životnog ciklusa, resurs se transformira dodavanjem nove vrijednosti u svakoj fazi. Neki procesi sudjeluju u životnim ciklusima različitih resursa i u različitim fazama transformacije resursa. Nakon treće faze (korištenja) resurs ili ostaje u sustavu, pri čemu tada posljednja faza podrazumijeva obnavljanje resursa za novi ciklus ili nestaje iz sustava. Nestajanjem se ne gubi materijalna i fizička vrijednost resursa, već on nestaje iz jednog sustava, da bi se pojavio u nekom drugom sustavu i tamo započeo novi ciklus.



Slika 3.1: Životni ciklus resursa

U nastavku će se za svaki resurs iz tablice 2.2. primjenom metode analize životnog ciklusa provjeriti kompletnost popisa poslovnih i akademskih procesa. Rezultati će biti prikazani opisno i grafički po uzoru na sliku 3.1.

Privremeni entitet: Student

Visoko učilište **raspisuje natječaj za upis** novih studenata na studijske programe. Učestalost natječaja može ovisiti o vremenskim ograničenjima upisa (npr. vezanim uz završetak školske godine u srednjoškolskom obrazovanju) ili o vrsti studijskog programa (preddiplomski, diplomski, specijalistički, stručni, doktorski, program cjeloživotnog obrazovanja). Sukladno tome neka visoka učilišta provede upise svake akademske godine, neka upisuju svakog semestra, a neka visoka učilišta mogu imati upise i tijekom akademske godine. Na natječaj se prijavljuju učenici sa završenom srednjom školom (ili odgovarajućim prethodnim obrazovanjem) i drugi potencijalni kandidati. Visoko učilište **provodi upisnu proceduru** koja može obuhvaćati vrednovanje srednjoškolskog uspjeha prema ocjenama, vrednovanje sposobnosti prema testiranju koje provodi specijalizirano državno tijelo (npr. državna matura), razredbeni postupak, klasifikacijski ispit, testiranje sposobnosti ili talenta, ili neku drugu odgovarajuću upisnu proceduru. Rezultat provedbe upisne procedure je lista kandidata koji su zadovoljili upisne kriterije te time stekli pravo upisa studija. Kandidati s liste mogu **upisati studij** prema raspoloživom broju slobodnih mjesta na studiju. Upisom na studij se kandidati smatraju studentima te time stječu prava i obveze koji proizlaze iz tog statusa. Studenti mogu odabrati i **upisati predmete** koje žele slušati i polagati svakog semestra ili u drugim vremenskim nastavnim jedinicama. Nastavnici visokog učilišta **izvode nastavu**, te nakon toga **održavaju ispite**. Studenti pristupaju ispitima, polažu predmete i stječu ECTS bodove (ECTS bodovi u Europi predstavljaju jedinicu opterećenja studenta i koristi se u svim zemljama koje su se na to obvezale prihvatanjem Bolonjske deklaracije), ocjene i/ili neki drugi oblik vrednovanja stečenog znanja. Nakon ispitnog perioda se provjerava ima li student uvjete za **upis novih predmeta** ili za završetak studija; ako nema dovoljno ECTS bodova za završetak studija (ili odgovarajućom provjerom sličnih uvjeta vezanih uz odabir predmeta), student može ponovno odabrati i upisati predmete koje želi slušati i polagati ih, čime se dio životnog ciklusa ponavlja u obliku petlje; inače student može odabrati temu završnog rada te dogovoriti mentorstvo s odabranim nastavnikom. Student prijavljuje **temu** završnog rada koja mora proći postupak **odobravanja**, nakon čega slijedi **organizacija obrane** rada. Nastavnik **mentorira** studenta pri izradi završnog rada te ili može sudjelovati u

ocjenjivanju završnog rada ili samo podržava studenta bez sudjelovanja u ocjeni. Kada obrani završni rad, student postaje apsolvent. Apsolventi se **promoviraju** u stečeno zvanje koje im obrazovanjem pripada te im se o stečenom zvanju **izdaju javne isprave** koje to potvrđuju. Mnoga visoka učilišta **organiziraju ALUMNI udruhu** koja i nakon studiranja osigurava vezu visokog učilišta i njezinih polaznika.

Trajanje jednog punog ciklusa može odgovarati trajanju studijskog programa (određeni broj semestara npr. 6, 8, 10 semestara) ili vremenu koje je potrebno studentu da ostvari dovoljan broj bodova (ili zadovolji druge kriterije koji su definirani nastavnim planom i programom). To znači da je moguće ponavljanje samo nekih procesa unutar istog slijeda procesa (npr. kada student upisuje predmete po semestru, a ne napušta sustav dok ne ponovi slijed spisa, slušanja i polaganja predmeta dovoljan broj puta), što je prikazano ljubičastom strelicom. Grafički je životni ciklus resursa student prikazan na slici 3.2.



Slika 3.2.: Analiza životnog ciklusa privremenog entiteta Student

Analizirani procesi omogućavaju transformaciju resursa student iz njegovog početnog oblika učenik (ili kandidat za upis) do njegovog konačnog oblika apsolvent, što vodi do zaključka da su prepoznati svi ključni procesi vezani uz razmatrani resurs student.

Stalni entitet: Nastavnik

Jedan od ključnih resursa visokog učilišta je izvođač nastavne djelatnosti – nastavnik. Nastavnici su obično raspoređeni u grupe sličnog znanstvenog i nastavnog područja rada, odnosno katedre. Na razini katedre se za nastavnike **planira** njihov **akademski razvoj**, odnosno opterećenje po obvezama i mogućnost napredovanja. Ovisno o zvanju u koje je nastavnik izabran, interesnom području i predmetima nastavnog plana i programa, određuju se njegove nastavne obveze: predavanja, auditorne vježbe, laboratorijske vježbe, seminarska nastava, vođenje praktikuma, obveze vezane uz mentorstvo i druge obveze. Kako bi se osigurala mogućnost napredovanja nastavnika, on ne smije biti preopterećen u nastavi već imati dovoljno vremena za znanstveni i stručni rad. Stoga se na razini katedre za sve nastavnike **raspoređuje opterećenje** u nastavi. Na temelju tog rasporeda, nastavnici **pripremaju nastavne materijalne, izvode nastavu i održavaju ispite, odobravaju teme završnih radova** i sudjeluju u **organizaciji obrane rada, mentoriraju studente** pri izradi završnih radova te **ocjenjuju radove** studenata. **Realizaciju planiranog opterećenja prati** katedra te odlučuje o rasporedu opterećenja za sljedeću nastavnu vremensku jedinicu (semestar, akademsku godinu, ili neku drugu nastavnu jedinicu). Rad sa studentima je jedan od čimbenika koji se uzima u obzir kod **napredovanja u zvanju** nastavnika.



Slika 3.3.: Analiza životnog ciklusa stalnog entiteta Nastavnik

Analizirani procesi omogućavaju izvedbu svih faza životnog ciklusa resursa nastavnik od početnog uvođenja u nastavu do planiranja opterećenja u sljedećoj nastavnoj vremenskoj jedinici, što vodi do zaključka da su prepoznati svi ključni procesi vezani uz razmatrani resurs nastavnik.

Stalni entitet: Znanstvenik

Znanstvenici su zaposlenici visokog učilišta koji se bave znanstveno istraživačkim radom. Ovisno o završenom stupnju obrazovanja, objavljenim radovima, znanstvenim postignućima i drugim kriterijima stječu znanstveno zvanje. Na razini visokog učilišta mlađi znanstvenici imaju mentora koji nadzire njihov rad te sudjeluje u raspodjeli nastavnih i stručnih opterećenja. Znanstvenici samostalno ili uz pomoć mentora **planiraju akademski razvoj**, odnosno opterećenje po obvezama i mogućnost napredovanja. Kako bi se osigurala mogućnost napredovanja zaposlenika, on ne smije biti preopterećen u nastavi kako bi imao dovoljno vremena za znanstveno istraživački rad. Stoga se na razini visokog učilišta **raspoređuje opterećenje** u nastavi, znanstvenim i stručnim projektima. Znanstvenici **provode istraživanja, rade na znanstveno istraživačkim projektima, razvijaju prototipove i pilot projekte, objavljuju znanstvene radove i izlažu na znanstvenim skupovima**. Realizaciju planiranog opterećenja prati katedra te odlučuje o rasporedu opterećenja za sljedeću vremensku jedinicu (semestar, akademsku godinu, ili vrijeme između dva izbora u zvanje). Objavljeni znanstveni radovi su važan čimbenik **napredovanja u zvanju** znanstvenika.



Slika 3.4.: Analiza životnog ciklusa stalnog entiteta Znanstvenik

Analizirani procesi omogućavaju izvedbu svih faza životnog ciklusa resursa znanstvenik kroz jedan ciklus od početnog uvođenja u znanstveni rad ili od početka znanstveno istraživačkog projekta do napredovanja u više zvanje i planiranja opterećenja u sljedećoj vremenskoj jedinici ili do završetka projekta, što vodi do zaključka da su prepoznati svi ključni procesi vezani uz razmatrani resurs znanstvenik.

Stalni entitet: Stručnjak

Zaposlenici visokog učilišta koji se bave znanstveno istraživačkim radom i nastavom ujedno su i vrhunski stručnjaci u izabranom interesnom području rada. Stoga se visoka učilišta mogu **prijavljivati na natječeaje** i nuditi **stručno komercijalne projekte**. Stručni i komercijalni projekti podrazumijevaju pružanje usluga savjetovanja, izrade ekspertiza, provedbu revizija projekata ili drugih poduhvata, konstruiranje proizvoda, izradu prototipova, te pružanje drugih stručnih usluga. Kako bi se osigurala mogućnost napredovanja zaposlenika, on ne smije biti preopterećen obvezama na stručnim projektima, kako bi imao dovoljno vremena za znanstveno istraživački rad i napredovanje. Stoga se na razini visokog učilišta **raspoređuje opterećenje** u nastavi, znanstvenim i stručnim projektima. Stručnjaci **rade na projektima, izrađuju proizvode ili pružaju usluge, prezentiraju klijentima** rezultate rada na projektu, **objavljaju stručne radove i izlažu na stručnim skupovima**. **Realizaciju planiranog opterećenja prati** katedra te odlučuje o rasporedu opterećenja za sljedeću vremensku jedinicu (semestar, akademsku godinu, ili kod pokretanja novog stručnog ili komercijalnog projekta). Objavljeni stručni radovi i postignuća mogu biti čimbenik **napredovanja u znanstvenom ili nastavnom zvanju**.



Slika 3.5.: Analiza životnog ciklusa stalnog entiteta Stručnjak

Analizirani procesi omogućavaju izvedbu svih faza životnog ciklusa resursa stručnjak od prijave projekta na natječaj do planiranja opterećenja u sljedećoj vremenskoj jedinici ili do završetka projekta, što vodi do zaključka da su prepoznati svi ključni procesi vezani uz razmatrani resurs stručnjak.

Ključni resurs: Nastavni plan i program

Nastavni plan i program (skraćeno: NPP) se planira tako da se formiraju predmeti nastavnog plana i programa i obveza na predmetima koje su potrebne za stjecanje diplome. Obveze se odnose na nastavu i polaganje ispita, obavljanje praktikuma te izradu završnih radova. Predmeti mogu biti uvjetovani izvedbom ili polaganjem nekog drugog predmeta (međuuvjetovanost predmeta). Ovaj postupak definiranja strukture studijskog programa se provodi jedanput, kod izrade nastavnog plana i programa, ali se može ponoviti kao redefiniranje nastavnog plana i programa kada je to potrebno, odnosno kada postoji potreba za promjenom. Prema planu i programu i za **studente upisane na studij se izvodi nastava, održavaju se ispiti, organizira i nadzire provedba praktikuma te ocjenjuju završni radovi**. Iz provedbe se dobivaju podaci za **kontrolu provedbe NPP**. Ako se u provedbi utvrdi potreba za promjenama, **predlažu se promjene NPP**, inače se postupak izvedbe odvija po istom NPP i u sljedećoj akademskoj cjelini.




Slika 3.6.: Analiza životnog ciklusa ključnog resursa Nastavni plan i program

Analizirani procesi omogućavaju izvedbu svih faza životnog ciklusa resursa nastavni plan i program od formiranja predmeta i obveza na predmetima nastavnog plana i programa prijave do revizije i predlaganja promjena NPP, što vodi do zaključka da su prepoznati svi ključni procesi vezani uz razmatrani resurs nastavni plan i program.

Ključni resurs: Predmet

Predmeti se **formiraju** pri definiranju **nastavnog plana i programa** kada se definira sadržaj i satnica predmeta, način izvođenja predmeta, postupak polaganja ispita, preduvjeti slušanja i polaganja predmeta i druga svojstva predmeta. Prilikom **upisa predmeta**, **provjerava se ispunjava li student preduvjete** za upis na kolegij. Nastavnici svake godine ažuriraju i **pripremaju nastavne materijale** za predmete. Predmeti se izvode te se objavljuju i održavaju ispitni rokovi. Na kraju semestra (ili neke druge nastavne cjeline) se kontrolira provedba nastavnog plana i programa te se po potrebi predlažu promjene NPP, a time i promjene predmeta.



Slika 3.7.: Analiza životnog ciklusa ključnog resursa Predmet

Analizirani procesi omogućavaju izvedbu svih faza životnog ciklusa resursa predmet od formiranja i definiranja predmeta i obveza na predmetima do revizije i predlaganja promjena NPP, što vodi do zaključka da su prepoznati svi ključni procesi vezani uz razmatrani resurs predmet.

Obnavljajući resurs: Novo temeljno znanje

Pod novim temeljnim znanjem se smatra znanstveni doprinos zaposlenika, objavljeni radovi, knjige, patent, projekti, inovacije, recepture, metodike, programski proizvodi, prototipovi ili neki drugi oblik rezultata znanstveno istraživačkog rada. Visoka učilišta i znanstvenici **planiraju znanstveno istraživačke projekte** te ih **prijavljaju na natječaje** za financiranje. Provedba projekata uključuje **provedbu istraživanja**, **razvijanje prototipova proizvoda** i **izvedbu pilot projekata**, **objavljivanje radova** i

recenziranje radova drugih znanstvenika. Voditelji znanstvenih projekata dužni su **izvješćivati o tijeku i rezultatima projekata.** Rad na znanstveno istraživačkim projektima se vrednuje kod **napredovanja u zvanju.**



Slika 3.8.: Analiza životnog ciklusa obnavljajućeg resursa Novo temeljno znanje

Analizirani procesi omogućavaju izvedbu svih faza životnog ciklusa resursa novo temeljno znanje od planiranja i prijave projekta do završetka projekta i postupka izbora/reizbora u zvanje, što vodi do zaključka da su prepoznati svi ključni procesi vezani uz razmatrani resurs.

Obnavljajući resurs: Novo primijenjeno znanje

Pod novim primijenjenim znanjem se smatra stručni doprinos zaposlenika, objavljeni rad, knjiga, proizvod, usluga, projekt, inovacija, receptura, metodika ili neki drugi oblik rezultata stručnog rada ili rada na komercijalnom projektu. Stručni doprinos je rezultat rada na stručnom ili komercijalnom projektu. Stručni i komercijalni projekti se **prijavljaju na natječaj**, stručnjaci **rade na projektu** i **izrađuju proizvode ili pružaju stručne usluge** savjetovanja, revizije, konstrukcije, planiranja, i sl. Stručnjaci **objavljaju stručne radove** (što se može i vrednovati kod izbora u zvanje u nekim strukama) i **održavaju stručne tečajeve, seminare** i radionice kako bi prenosili stručna znanja u javnost i gospodarstvo. Voditelji stručnih i komercijalnih projekata dužni su **izvješćivati o tijeku i rezultatima projekata.**



Slika 3.9.: Analiza životnog ciklusa obnavljajućeg resursa Novo primijenjeno znanje

Analizirani procesi omogućavaju izvedbu svih faza životnog ciklusa resursa novo primijenjeno znanje od planiranja i prijave projekta do završetka projekta, što vodi do zaključka da su prepoznati svi ključni procesi vezani uz razmatrani resurs.

Ključni resurs: Tehnička infrastruktura i oprema

Tehnička infrastruktura obuhvaća zgrade, dvorane, laboratorije, komunikacijske veze i drugu infrastrukturnu opremu koja je potrebna za izvedbu poslovnih procesa visokog učilišta. Investicije u infrastrukturu i održavanje se **planiraju u proračunu** visokog učilišta. Investicijski projekti za koje je osigurano financiranje se **pripremaju** i ugovaraju, nakon čega dobavljači provode ugovorene usluge i radove. Potrošna roba i **oprema se nabavlja, raspoređuje i ugrađuje te održava**. Odgovorna osoba na visokom učilištu **nadzire provedbu investicijskih projekata i nabavu opreme, odobrava plaćanja i nadzire izvršenje proračuna**.



Slika 3.10.: Analiza životnog ciklusa ključnog resursa Tehnička infrastruktura i oprema

Analizirani procesi omogućavaju izvedbu svih faza životnog ciklusa resursa tehničke infrastrukture i opreme od planiranja proračunskih stavaka do nabave i plaćanja, što vodi do zaključka da su prepoznati svi ključni procesi vezani uz razmatrani resurs.

Ključni resurs: Novac

Financijski resursi visokog učilišta se prikupljaju iz raznih izvora, a namijenjeni su nastavnoj, znanstvenoj i stručnoj djelatnosti. Vodstvo visokog učilišta donosi **plan poslovanja** za koji se **planira proračun**. Ovisno o organizacijskom ustroju i glavnom izvoru financiranja proračun se u nekim učilištima usuglašava na nekoliko hijerarhijskih poslovnih razina. Vodstvo upravlja poslovanjem visokog učilišta odobrava uplate i isplate, obračune i fakture, **nadzire izvršenje proračuna** i **izvješćuje o financijskom poslovanju** nadležne institucije i financijere. Stručne službe visokih učilišta su zadužene za operativne poslove vezane uz **obračun i fakturiranje, evidentiranje uplata i provedbu plaćanja, knjiženje poslovnih događaja i izvješćivanje** vodstva o izvršenju planiranih stavaka proračuna.



Slika 3.11.: Analiza životnog ciklusa ključnog resursa Novac

Analizirani procesi omogućavaju izvedbu svih faza životnog ciklusa resursa novac od planiranja proračunskih stavaka do nadzora nad izvršenjem proračuna i izvješćivanjem o financijskom poslovanju, što vodi do zaključka da su prepoznati svi ključni procesi vezani uz razmatrani resurs.

3.3. Analiza kompletnosti popisa procesa s obzirom na značaj procesa za ostvarenje misije

Nakon prve faze provjere kompletnosti procesa analizom životnog ciklusa ključnih resursa, potrebno je analizirati kompletnost popisa poslovnih i akademskih procesa s obzirom na njihov značaj za ostvarenje misije visokih učilišta. Procesi su raspoređeni u Porterov lanac vrijednosti (*engl. Value Chain*) što omogućava procjenu i razvrstavanje procesa po njihovom značaju na one koji imaju potporni značaj za ostvarenje temeljnih djelatnosti i onih koji izravno sudjeluju u generiranju profita i ostvarenju misije postojanja organizacije. Prema autorima Ruskov i Ruskov [81], modeliranje lanaca vrijednosti visokih učilišta osigurava transparentnost i objašnjava veza između aktivnosti nastavne i znanstvene djelatnosti. Raspored procesa po Porterovom lancu vrijednosti [76] će kasnije biti korišten za analizu učinkovitosti postojećeg informacijskog sustava, ali i određivanje prioriteta buduće informatizacije visokih učilišta. Osnovni prikaz Porterovog lanca vrijednosti [76] je prikazan na slici 3.12.



Slika 3.12.: Osnovni prikaz Porterovnog lanca vrijednosti

Na glavnoj osi lanca vrijednosti nalaze se one funkcije organizacije koje najviše pridonose generiranju vrijednosti, odnosno ostvarenju misije:

1. **Nabavna logistika** (Inbound Logistics) – procesi koji omogućavaju i/ili osiguravaju ulaz resursa potrebnih za generiranje proizvoda ili usluge.
2. **Radni postupci** (Operations) – procesi koji su karakteristični za djelatnost organizacije, a koji nabavljene ulazne resurse pretvaraju u konačni proizvod ili uslugu.

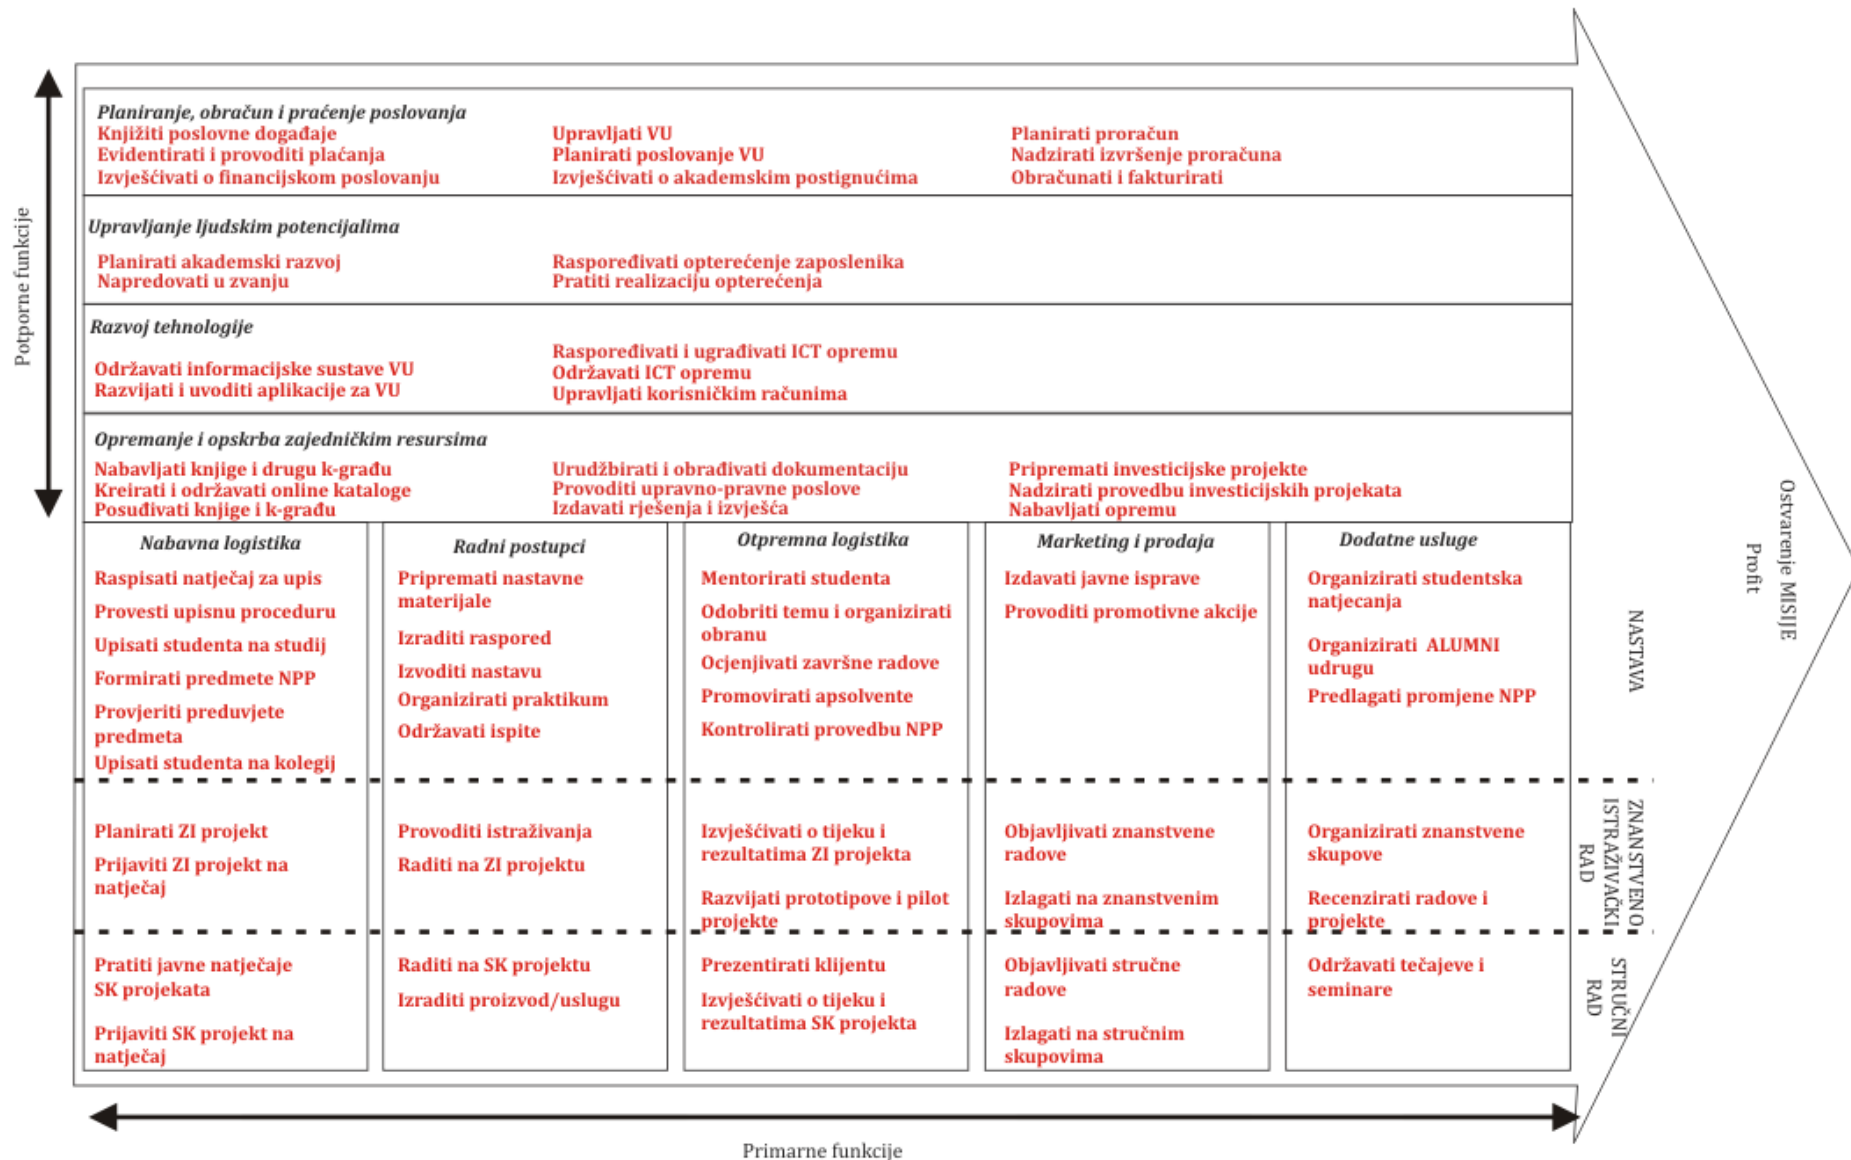
3. **Otpremna logistika** (Outbound Logistics) – procesi koji omogućavaju i/ili osiguravaju tehničke i organizacijske uvjete za isporuku proizvoda ili usluge.
4. **Marketing i prodaja** (Marketing and Sales) – procesi kojima se informira i motivira ciljna skupina (budućih) korisnika na kupnju ili korištenje raspoloživih usluga ili proizvoda, te procesi završne isporuke proizvoda ili usluge.
5. **Dodatne usluge** (Service) – procesi koji omogućavaju poslijeprodajne kontakte i pružanje dodatnih usluga kojima se nastoji osigurati zadovoljstvo kupca ili korisnika usluge, a time i lojalnost prema proizvođaču ili pružatelju usluge.

Osim temeljnih poslovnih procesa, poslovnu tehnologiju organizacije čine još i potporni procesi koje prema *Value Chain* metodi dijelimo u 4 funkcije:

1. **Opremanje i opskrba zajedničkim resursima** (Procurement) – procesi vezani uz nabavu resursa koji se koriste u cjelokupnoj organizaciji te nisu karakteristični za djelatnost organizacije.
2. **Upravljanje ljudskim potencijalima** (Human Resource Management) – procesi kojima se planira i generira potrebna kadrovska struktura zaposlenih.
3. **Razvoj tehnologije** (Technology Development) – procesi koji podrazumijevaju ulaganje napora za razvoj novih znanja, vještina, poslovnih procesa, tehničke tehnologije rada, proizvoda, usluga, opreme i drugih ključnih područja kojima će se omogućiti budući razvoj organizacije.
4. **Planiranje, obračun i praćenje poslovanja** (Firm Infrastructure) – procesi koji osiguravaju protočan rad sustava, povezivanjem svih dijelova organizacije.

Ustroj procesa visokih učilišta i funkcionalni zahtjevi koji iz njih proizlaze predstavljaju temelj za izradu koncepta informacijskog sustava visokih učilišta. Primarne funkcije i njihovi procesi izravno utječu na i sudjeluju u ostvarenju misije organizacije te rezultiraju prihodom i profitom organizacije, te zbog toga svi resursi (pa tako i informacijski resursi) moraju biti u funkciji ostvarenja misije ili generiranja profita. Prema Porterovoj ideji, značaj informacijskog sustava se može sagledavati kroz njegovu potporu primarnim funkcijama i procesima organizacije. Što su primarne funkcije i procesi (prikazani na glavnoj osi lanca vrijednosti) jače podržane informacijskim sustavom, to je IS bolje u funkciji temeljne djelatnosti organizacije.

Na slici 3.13. su prikazani rezultati razvrstavanja poslovnih i akademskih procesa visokih učilišta u Porterov lanac vrijednosti.



Slika 3.13.: Rezultati razvrstavanja poslovnih i akademskih procesa visokih učilišta u Porterov lanac vrijednosti

Procese visokih učilišta treba razmatrati kroz dva aspekta: (1) akademski aspekt koji visoka učilišta izdvaja kao specifične organizacije sa jedinstvenim procesima i (2) poslovni aspekt koji ukazuje na to da se neki procesi organizacija odvijaju na sličan način u većini organizacija. Proces visokih učilišta kod kojih je naglašen poslovni značaj samo posredno doprinose poslovnom uspjehu i ostvarenju misije postojanja. Proces s naglašenim akademskim značajem su procesi koji visokom učilištu donose stratešku prednost te stoga primjena informacijskih i komunikacijskih tehnologija za potporu tim procesima mora biti dizajnirana prema funkcionalnim zahtjevima koji proizlaze iz procesa visokog učilišta. Pritom treba i objektivno ocijeniti prioritete informatizacije, na način da se primjenom odgovarajućih metoda strateške analize ocijeni ovisnost izvođenja procesa o upotrebi ICT te odrede koristi tako informatiziranih procesa na poslovni rezultat. U tu svrhu se može primijeniti BCG matrica izvedena iz McFarlanove Portfolio matrice [96] s odgovarajućim kriterijima za stratešku analizu prioriteta informatizacije: „U BCG matrici se poslovni procesi razmatraju, s obzirom na upotrebu ICT, prema dva kriterija: (a) kolika ušteda može nastati primjenom suvremenih ICT te, (b) u kojoj mjeri je izvođenje procesa ovisno o upotrebi ICT. Ako se ovi kriteriji promatraju kao dvije nezavisne varijable i upišu na ortogonalne osi dvodimenzionalnog koordinatnog sustava te odrede dvije diskretne vrijednosti na svakoj od ovih osi (uštede: **male-velike**, ovisnost: **mala-velika**), dobije se matrica s četiri polja. Sve procese iz analizirane organizacije treba razmjestiti u polja matrice po opisanim kriterijima. Svako od tih polja biti će tako popunjeno s više procesa za koje ICT ima sličan značaj:

Potporni procesi su smješteni u donji lijevi kvadrant, gdje su očekivane uštede male a i zavisnost učinkovitog izvršavanja tih procesa o ICT je također mala. Potpora procesima ovog tipa realizira se aplikacijama koje nisu kritične za organizaciju.

Operativni procesi su oni koji se bez upotrebe ICT praktično ne bi mogli izvoditi, ali se njihovom informatizacijom može ostvariti tek mala ušteda. Takvi se procesi u svakoj organizaciji moraju informatizirati, jer se drugačije jednostavno ne bi moglo raditi.

Izgledni procesi su oni koji trenutno nisu u većoj mjeri uvjetovani primjenom ICT, ali bi se njihovom informatizacijom u budućnosti mogle ostvariti velike uštede u troškovima poslovanja. Takve procese treba svakako uzeti u obzir kod planiranja daljnje informatizacije.

Strateški procesi su oni čije učinkovito izvođenje snažno zavisi o primjeni suvremenih ICT, a istovremeno imaju veliki utjecaj na smanjenje troškova organizacije. Informatizacija takvih procesa mora imati apsolutni prioritet u svakoj organizaciji.“ [10]. Na slici 3.14. je prikazana BCG matrica procesa visokih učilišta. Poslovni procesi visokih učilišta su raspoređeni prema zadanim kriterijima u jednu od četiri definirane skupine. Oni procesi čiji su nazivi na slici podvučeni su primarni procesi generiranja novih vrijednosti, jer prema analizi lanca vrijednosti leže na glavnoj osi. Povezivanjem rezultata Porterove kategorizacije primarnih i potpornih procesa sa rasporedom procesa u BCG matrici možemo definirati koji procesi moraju najprije biti podržani ICT (to su procesi koji se prema Porterovoj kategorizaciji nalaze na glavnoj osi) poštujući s druge strane preporuku rasporeda poslovnih procesa u BCG analizi, odnosno njihove važnosti s obzirom na operativni, potporni, izgledni i strateški značaj procesa u cjelokupnoj poslovnoj tehnologiji. Procesu sa oznakom *, mogu imati i drugi položaj u matrici, a to može ovisiti o znanstvenom području djelatnosti.

Ovisnost poslovnih procesa o informacijskoj tehnologiji	Velika	2 OPERATIVNI procesi <u>Formirati predmete NPP</u> <u>Predlagati promjene NPP</u> <u>Provjeriti preduvjete predmeta</u> <u>Pripremati nastavne materijale</u> <u>Izraditi raspored</u> <u>Recenzirati radove i projekte</u> <u>Prezentirati klijentu*</u> <u>Izvešćivati o tijeku i rezultatima ZI projekta</u> <u>Izvešćivati o tijeku i rezultatima SK projekta</u> <u>Izvešćivati o financijskom poslovanju</u> <u>Izvešćivati o akademskim postignućima</u> Razvijati i uvoditi aplikacije za VU Održavati informacijske sustave VU Nabavljati knjige i drugu k-građu Kreirati i održavati online kataloge Knjižiti poslovne događaje Evidentirati i provoditi plaćanja Obračunati i fakturirati Upravlјati korisničkim računima Posuđivati knjige i k-građu Urudžbirati i obrađivati dokumentaciju Nabavljati opremu	4 STRATEŠKI procesi <u>Provesti upisnu proceduru</u> <u>Upisati studenta na studij</u> <u>Upisati studenta na kolegij</u> <u>Izvoditi nastavu</u> <u>Organizirati praktikum</u> <u>Odobriti temu i organizirati obranu</u> <u>Ocjenjivati završene radove</u> <u>Prijaviti ZI projekt na natječaj</u> <u>Provoditi istraživanja</u> <u>Raditi na ZI projektu</u> <u>Razvijati prototipove i pilot projekte*</u> <u>Prijaviti SK projekt na natječaj</u> <u>Raditi na SK projektu</u> <u>Izraditi proizvod/uslugu*</u> <u>Organizirati znanstvene skupove*</u> <u>Održavati tečajeve i seminare*</u> Raspoređivati opterećenje zaposlenika Pratiti realizaciju opterećenja Kontrolirati provedbu NPP
	Mala	1 POTPORNI procesi <u>Održavati ispite</u> <u>Mentorirati studenta</u> <u>Promovirati apsolvente</u> <u>Planirati akademski razvoj</u> <u>Napredovati u zvanju</u> Provoditi upravno-pravne poslove Izdavati rješenja i izvješća Izdavati javne isprave Raspoređivati i ugrađivati ICT opremu Održavati ICT opremu Pripremati investicijske projekte Nadzirati provedbu investicijskih projekata	3 IZGLEDNI procesi <u>Raspisati natječaj za upis</u> <u>Planirati ZI projekt</u> <u>Pratiti javne natječaje SK projekata</u> <u>Objavljivati znanstvene radove</u> <u>Objavljivati stručne radove</u> <u>Izlagati na znanstvenim skupovima</u> <u>Izlagati na stručnim skupovima</u> Planirati poslovanje VU Upravlјati VU Planirati proračun Nadzirati izvršenje proračuna <u>Provoditi promotivne akcije</u> <u>Organizirati studentska natjecanja</u> <u>Organizirati ALUMNI udrugu</u>
		Nizak	Visok

Utjecaj informacijskih tehnologija na uspješnost rada visokog učilišta

Slika 3.14.: Značaj poslovnih i akademskih procesa prema BCG matrici procesa VU

Procesi koji se nalaze na glavnoj osi profitnog lanca, a pripadaju skupini procesa od potpornog značaja za visoka učilišta su sljedeći: Održavati ispite, Mentorirati studenta, Promovirati apsolvente, Planirati akademski razvoj, Napredovati u zvanju. Njihova informatizacija nije prioritetna.

Procesi koji se nalaze na glavnoj osi profitnog lanca, a pripadaju skupini procesa od operativnog značaja za visoka učilišta su sljedeći: Formirati predmete NPP, Predlagati

promjene NPP, Provjeriti preduvjete predmeta, Priprijeti nastavne materijale, Izraditi raspored, Recenzirati radove i projekte, Prezentirati klijentu, Izvješćivati o tijeku i rezultatima ZI projekta, Izvješćivati o tijeku i rezultatima SK projekta, Izvješćivati o financijskom poslovanju, Izvješćivati o akademskim postignućima. Njihova informatizacija ima najveći prioritet jer će stvoriti preduvjete za informatizaciju strateških i izglednih procesa.

Procesi koji se nalaze na glavnoj osi profitnog lanca, a pripadaju skupini procesa od strateškog značaja za visoka učilišta su sljedeći: Provesti upisnu proceduru, Upisati studenta na studij, Upisati studenta na kolegij, Izvoditi nastavu, Organizirati praktikum, Odobriti temu i organizirati obranu, Ocjenjivati završene radove, Prijaviti ZI projekt na natječaj, Provoditi istraživanja, Raditi na ZI projektu, Razvijati prototipove i pilot projekte, Prijaviti SK projekt na natječaj, Raditi na SK projektu, Izraditi proizvod/uslugu, Organizirati znanstvene skupove, Održavati tečajeve i seminare, Kontrolirati provedbu NPP. Strateški procesi imaju veći prioritet u odnosu na izgledne procese, ali manji prioritet od operativnih procesa. Njihova informatizacija je važna jer doprinosi strateškom razvoju visokog učilišta.

Procesi koji se nalaze na glavnoj osi profitnog lanca, a pripadaju skupini procesa od izglednog značaja za visoka učilišta su sljedeći: Raspisati natječaj za upis, Planirati ZI projekt, Pratiti javne natječaje SK projekata, Objavljivati znanstvene radove, Objavljivati stručne radove, Izlagati na znanstvenim skupovima, Izlagati na stručnim skupovima, Provoditi promotivne akcije, Organizirati studentska natjecanja, Organizirati ALUMNI udruhu. Njihova informatizacija može u budućnosti doprinijeti razvoju visokog učilišta.



Pomoću BCG matrice su načelno definirani prioriteti informatizacije procesa visokih učilišta, no postavlja se pitanje kako informatizirati, odnosno je li bolje razvijati vlastiti informacijski sustav za visoka učilišta ili kupiti gotovi IS? Odgovor na ovo pitanje nije lako pronaći, jer postoje prednosti i nedostaci svakog mogućeg pristupa u rješavanju ovog pitanja. U slučaju kada visoko učilište raspolaže vremenskim, financijskim, tehnološkim, tehničkim i drugim resursima u koje ima povjerenja, definitivno bi prva opcija trebala biti razvoj vlastitog informacijskog sustava, koji će osigurati stratešku prednost poslovanju time što će se projektirati i razviti informacijski sustav „po mjeri“ visokog učilišta.

3.4. Model poslovnih i akademskih procesa visokih učilišta

Poslovni i akademski procesi visokih učilišta međusobno razmjenjuju različite sadržaje. Ti se sadržaji razmjenjuju tokovima koji mogu biti ulazni ili izlazni u odnosu na proces. Ulazne sadržaje proces koristi kako bi kreirao izlazne sadržaje. Na slici 3.15. je prikazan prijedlog modela poslovnih i akademskih procesa visokih učilišta koji obuhvaća i procese i tokove sa sadržajima.

Model je izrađen primjenom notacije za modeliranje poslovnih procesa (*engl. Business Process Model and Notation*, skraćeno BPMN [13]). Osnovni simboli korištenog alata za modeliranje Websphere Business Modeler su usklađeni sa BPMN-om, a objašnjeni su u tablici 3.3.

Tablica 3.3.: Opis značenja simbola korištenih u modelu procesa

Grafički prikaz simbola	Značenje
	Slijedni tok (<i>Sequence Flow</i>) je prikazan punom crtom sa strelicom, a označava slijed u kojem će se izvršavati aktivnosti. Sadržaj toka je iskazan nazivom sadržaja na strelici.
	Informacijski tok (<i>Message Flow</i>) je prikazan crtkanom strelicom, a opisuje kretanje podataka između repozitorija i procesa/aktivnosti. Sadržaj toka je iskazan nazivom sadržaja na strelici.
	Aktivnost (<i>Activity</i>) je opći i generički pojam, a označava rad unutar sustava. Može biti <u>elementarna</u> (<i>atomic</i>) ili <u>složena</u> (<i>compound</i>). Tipovi aktivnosti su: <ul style="list-style-type: none">– Proces (<i>Process</i>),– Podproces (<i>Sub-Process</i>) i– Radnja (<i>Task, Atomic activity</i>).
	Događaji koji utječu na slijed izvršavanja aktivnosti. Mogu biti: <ul style="list-style-type: none">• Početni događaj (zeleni kružić): događaj koji pokreće izvršenje početne aktivnosti slijeda.• Prekid (kružić sa znakom X): događaj označava da je korisnik odlučio prekinuti proces uz normalnu obradu događaja.• Završetak (krug sa crnim kružićem): sve aktivnosti (i njihove instance) se odmah prekidaju. Proces završava bez kompenzacije ili obrade prekida.

	<p>Vrata (<i>Gateway</i>) koja se označavaju rombom se koriste za prikaz grananja (<i>branching</i>). Broj grana je kod jednostavnih vrata ograničen na dva, dok je kod implicitnog grananja maksimalan broj grana proizvoljan.</p>
	<p>Vrata (<i>Gateway</i>) koja se označavaju trokutom se koriste za prikaz spajanja (<i>merging</i>). Broj ulaznih grana koje se spajaju je proizvoljan, a za aktiviranje vratiju je dovoljno aktiviranje jedne ulazne grane.</p>
	<p>Vrata (<i>Gateway</i>) koja se označavaju okomitim pravokutnikom s više ulaznih grana koriste za prikaz združivanja (<i>joining</i>). Broj ulaznih grana koje se spajaju je proizvoljan, a za aktiviranje vratiju je potrebno aktiviranje svih ulaznih grana.</p>
	<p>Vrata (<i>Gateway</i>) koja se označavaju okomitim pravokutnikom s više izlaznih grana koriste za prikaz razdvajanja (<i>forking</i>). Broj izlaznih grana koje se paralelno šalju u različite aktivnosti proizvoljan.</p>
	<p>Vremski pokazivač (<i>Timer</i>) označava apsolutno vrijeme ili vremenski ciklus u kojem se pokreće ili nastavlja neka aktivnost.</p>
	<p>Spremnik podataka (<i>Repository</i>) koji prikazuje klase podataka koje aktivnost čita ili kreira.</p>

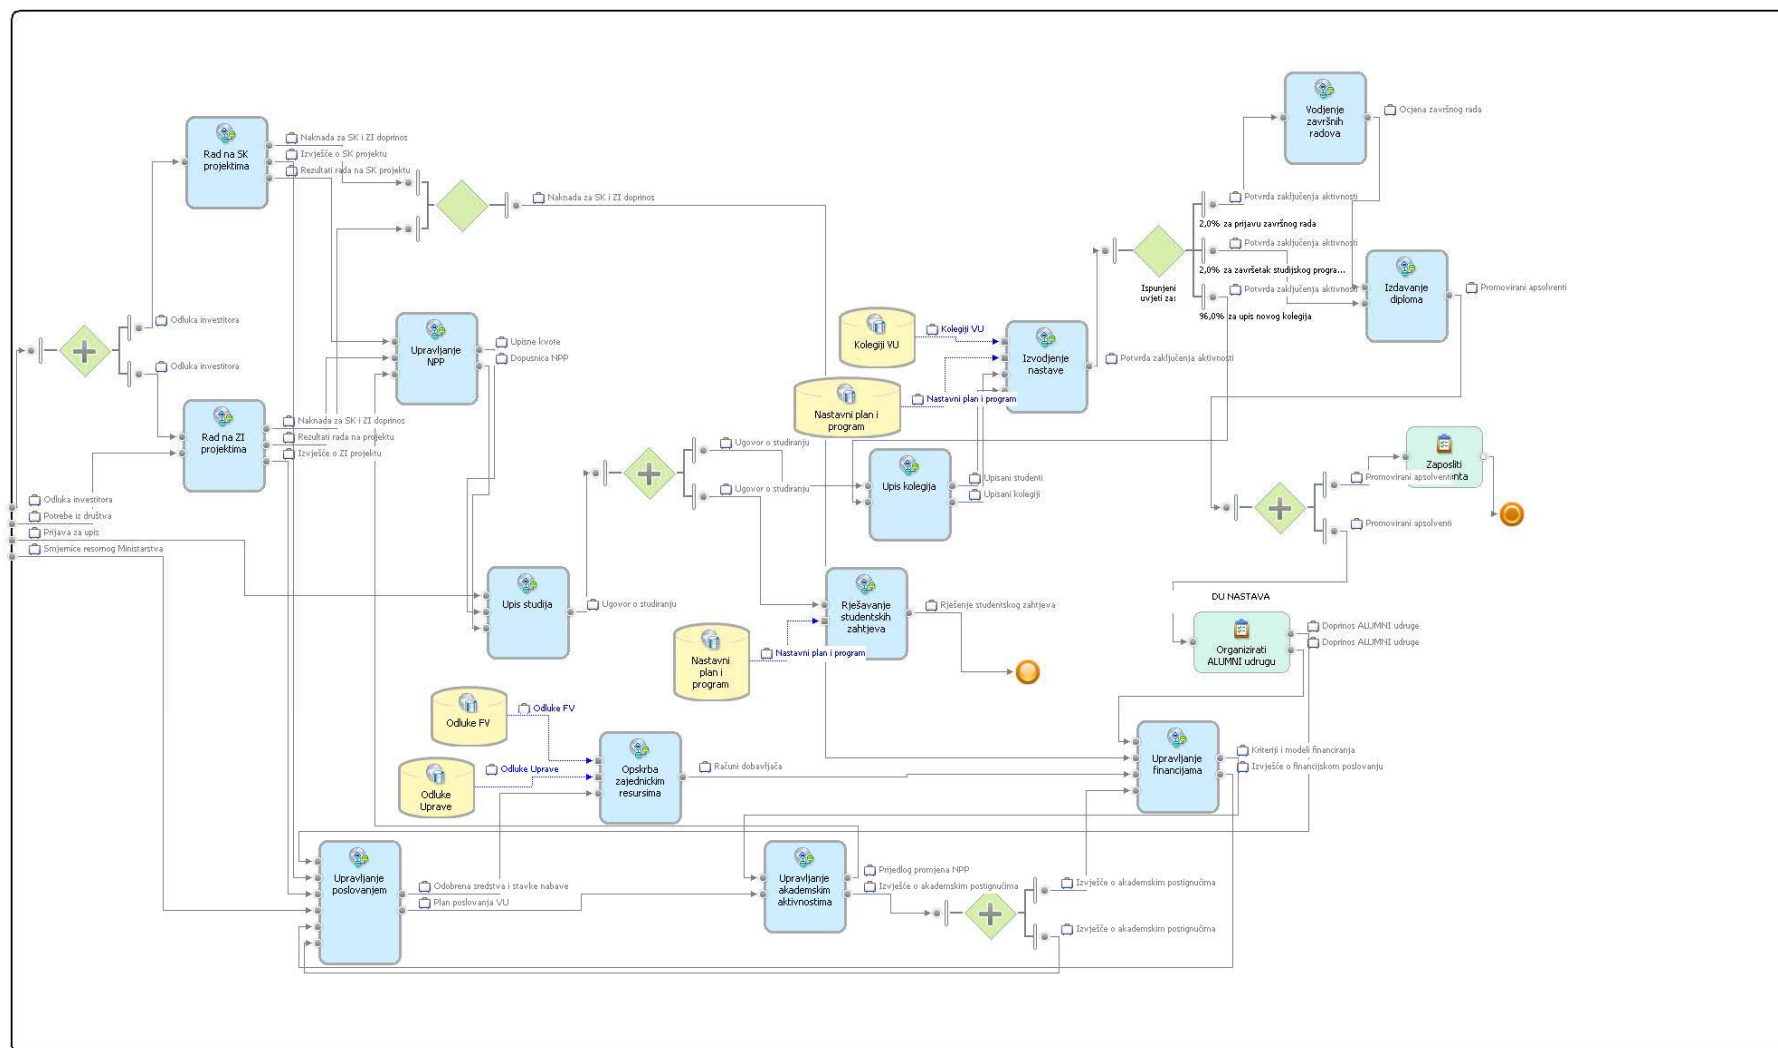
Model na slici 3.15. predstavlja pregledni model koji prikazuje 13 složenih procesa i dva jednostavna. Složeni procesi su prikazani pojedinačnim modelima na slikama 3.16. do 3.28., a obuhvaćaju sve procese iz popisa procesa s početka poglavlja, procese koje izvode studenti i procese okoline koji utječu na izvođenje procesa visokih učilišta. Na modelima složenih procesa je iznad simbola aktivnosti (pravokutnika) ispisan klasifikator procesa ili prema Porterovom modelu za procese visokog učilišta, ili vrijednosti klasifikatora „student“ za studentske aktivnosti za procese koje izvršavaju studenti, ili vrijednost „okruženje“ za poslove okoline s utjecajem na rad VU za preostale procese. Pregledni model je izrađen radi sinteze složenih modela, preglednosti i prikaza sinergijskog učinka veza pojedinačnih modela procesa. U modeliranju i unapređenju procesa se promjene zapravo uvode na procesima nižih razina složenosti (odnosno na detaljnim modelima kao što su modeli 3.16. do 3.28.), a promjene na tim modelima se reflektiraju na sveukupnu tehnologiju rada (prikazanu na slici 3.15).

Procesi su tokovima povezani u sljedove koji logički čine jednu cjelinu poslova. Primjer slijeda procesa možemo opisati primjerom poslova vezanih uz upis studenta na studijski program visokog učilišta: Visoka učilišta formiraju predmete nastavnih planova i programa. Nastavni planovi i programi se šalju na odobravanje. Ako je nastavni plan i program prihvaćen od strane nadležnog tijela (Sveučilišta, resornog Ministarstva), onda se visokom učilištu izdaje se dopusnica za izvođenje NPP-a. Za NPP koji se u akademskoj godini izvode na visokom učilištu resorno ministarstvo odobrava upisne kvote koje će se financirati iz državnog proračuna. Ovaj opisani postupak mora biti završen prije roka za upis na studij, kojeg određuje svako visoko učilište, a koji se mora održati nakon završetka školske godine u srednjoškolskim obrazovnim institucijama.

Kada nastupi rok za upis, visoko učilište raspisuje natječaj za upis. Kandidati za upis prate objave natječaja za upis, ili za natječaje saznaju preko drugih promotivnih aktivnosti visokih učilišta. Sve prijave za upis prolaze upisnu proceduru, u kojoj se uz osnovnu dokumentaciju studenta uzimaju u obzir i kvalifikacije kandidata kao što su npr. rezultati državne mature ili svjedodžbe iz srednjih škola. Visoko učilište autonomno određuje uvjete za upis i propisuje upisnu proceduru. Prihvaćene prijave za upis omogućavaju upis kandidata na studij. Potpisivanjem ugovora o studiranju kandidati prihvaćaju uvjete studiranja i time stječu prava i obveze. Jedno od prava jest dobivanje korisničkog elektroničkog računa za pristup informacijskom sustavu visokog učilišta te time i drugim resursima i procesima visokog učilišta. Na isti način treba čitati ostale modele.

Procesi i aktivnosti na modelima su povezane tokovima (strelicama ili vezama) koje predstavljaju podatkovne i materijalne sadržaje koje procesi međusobno razmjenjuju. Njihov smjer treba shvatiti uvjetno, kao slijed kojim je prikazan jedan prolaz entiteta student, nastavni plan i program, projekt ili drugih entiteta. Naime, procesi i aktivnosti ne „čekaju“ da se izvede strelicama prikazan slijed prije njih, jer organizacija u stvarnom svijetu ne čeka pojavu (instancu) entiteta, već se procesi i aktivnosti kontinuirano izvode uzimajući u obzir logiku iskazanu slijednim vezama. Tamo gdje se na modelu želi iskazati neko „čekanje“ ili povremeno izvođenje procesa ili aktivnosti, uveden je vremenski okidač koji djeluje kao pokretački događaj (*engl. Timer*).

Model procesa je izrađen sa svrhom identifikacije procesa visokih učilišta i podataka koji su potrebni kako bi se korištenjem resursa moglo planirati i upravljati, a ne za simulaciju trošenja resursa. Za operativnu primjenu modela u planiranju troškova resursa treba svakoj aktivnosti (procesu) dodijeliti izravne i neizravne troškove po jedinici izvođenja aktivnosti te prilagoditi učestalost ulaznih i izlaznih tokova.



Slika 3.15.: Pregledni model procesa visokog učilišta

Opis procesa vezanih uz upravljanje nastavnim planom i programom

Izvođenje nastavne djelatnosti ne može započeti bez procesa upravljanja nastavnim planovima i programima visokih učilišta. Kod formiranja predmeta nastavnog plana i programa nastavnici koriste spoznaje i znanja stečena tijekom rada na znanstvenim i stručnim projektima te, ako ih ima, prijedloge promjena iz prethodnih izvedbenih kontrola provedbe NPPa. Nadležna tijela Ministarstva razmatraju i odobravaju nastavne planove i programe studija te odobravaju upisne kvote za studijske programe. Na kraju obrazovnog ciklusa kontrolira se provedba nastavnog plana i programa te se daju prijedlozi promjena radi unapređenja.

Opisani postupak je primjenjiv za sve studije. Moguće su različite inačice procesa formiranja predmeta koje se razlikuju po operativnom načinu definiranja predmeta, njihove međusobne uvjetovanosti, simuliranja opterećenja studenata i nastavnog osoblja. Postupak odobravanja nastavnih planova i programa se razlikuje kod nadležnog tijela za različite oblike studija (preddiplomski, diplomski, stručni, specijalistički i doktorski studiji). Proces odobravanja upisnih kvota se trenutno izvodi samo na temelju dopusnica, iako visoka učilišta ukazuju na potrebu predviđanja potreba sa tržišta rada.

Kontrola provedbe nastavnih planova i programa se izvodi na temelju rasporeda (kao planske veličine) i podataka o stvarnoj realizaciji nastave. Odstupanja od planiranog izvršenja se evidentiraju, a podaci o izvršenju plana nastave i opterećenja se uzimaju u obzir kod prijedloga promjena.

Opis procesa vezanih uz upis studija

Inicijalni slijed procesa vezanih uz upis studija se pokreće prema akademskom kalendaru, odnosno kada visoka učilišta objave upisni rok studija. Tada se raspisuje natječaj za upis studenata na studijske programe. Potencijalni studenti pokreću upisnu proceduru prijavom na natječaj. Prijave za upis se analiziraju i provodi se upisna procedura. Prihvaćene prijave omogućavaju studentu upis na studijski program. Nakon što student prihvati uvjete, obveze i prava koja proizlaze iz statusa studenta, student prihvaća prijedlog ugovorenih obvezan visokog učilišta. Svim upisanim studentima se dodjeljuje korisnički račun za pristup informacijskom sustavu visokog učilišta.

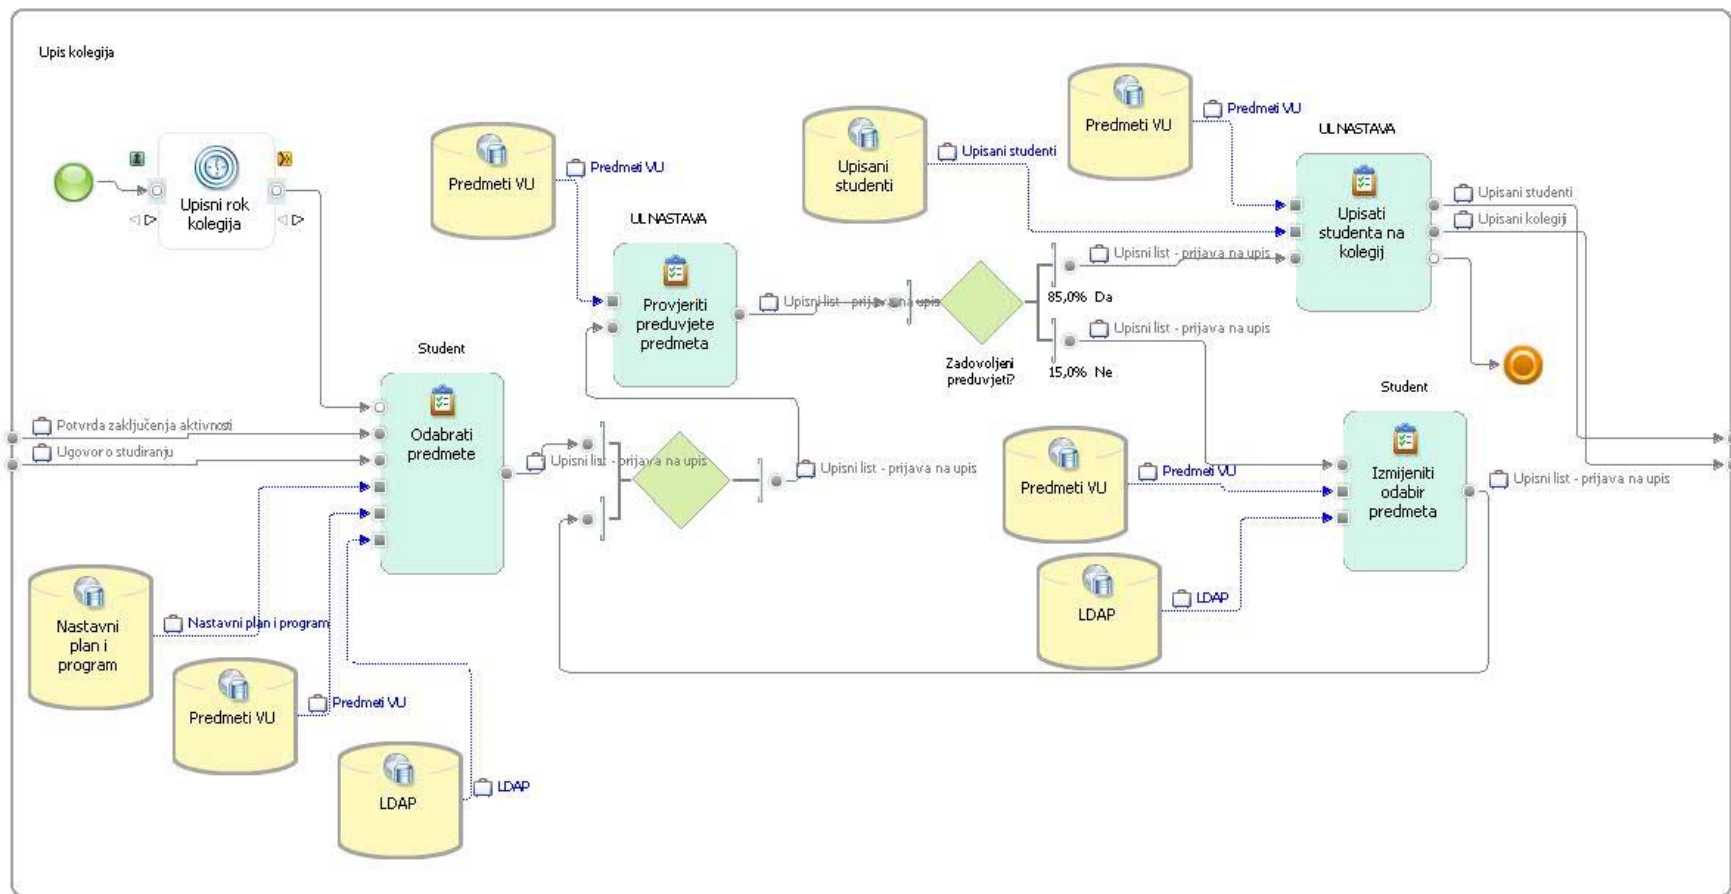
Inačice procesa su moguće kod provođenja upisne procedure. Visoka učilišta mogu koristiti ulazne kvalifikacijske rezultate drugih tijela obrazovnog sustava (npr. rezultate državne mature) i/ili zahtijevati dodatne provjere kvalifikacija potencijalnih studenata. Procedura obuhvaća bodovanje različitih kvalifikacija, što omogućava rangiranje potencijalnih studenata i izbor najboljih kandidata za upis.

Učestalost prijava za upis može se mijenjati s obzirom na odabir potencijalnih studenata. U tom kontekstu, visoka učilišta provode promotivne akcije i organiziraju studentska natjecanja koja doprinose razvoju kompetitivne klime među studentima i studente potiče na izvrsnost. Učestalost natjecanja i promotivnih aktivnosti je promjenjiva i također treba biti planirana u sklopu akademskog kalendara.

Opis procesa vezanih uz upis kolegija

Visoka učilišta omogućavaju upis predmeta prema akademskom kalendaru studijskog programa. Studenti odabiru predmete nastavnog plana i programa, a odabir unose u informacijski sustav koristeći svoj korisnički račun za pristup podacima i aplikacijama IS-a. Na temelju međusobne uvjetovanosti predmeta (npr. preduvjet odslušanog ili položenog predmeta, određeni broj ECTS bodova u određenoj kategoriji bodova, planirani raspored izvođenja predmeta u akademskoj godini, ili drugim uvjetima), provodi se provjera mogućnosti upisa na kolegij.

Upis kolegija se provodi na temelju odabira studenta i procedure provjere implementirane u informacijski sustav. Ako su preduvjeti zadovoljeni, student se upisuje kao polaznik predmeta. Ako preduvjeti nisu zadovoljeni, student treba odabrati drugi predmet.

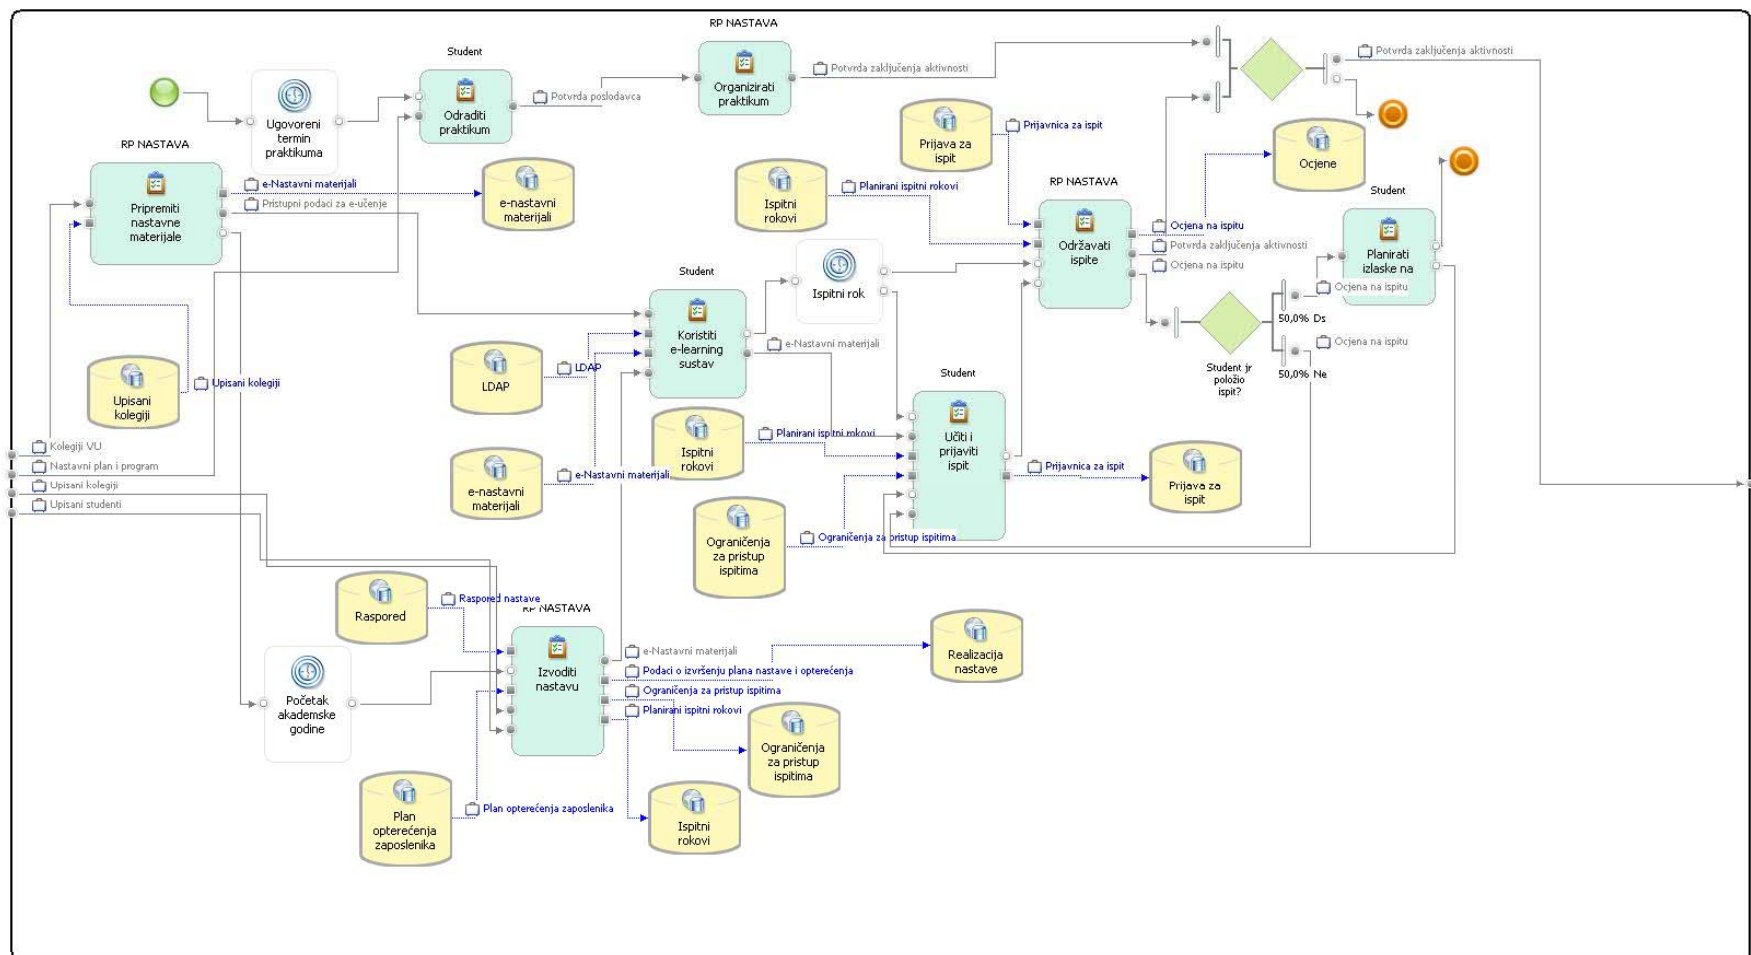


Slika 3.18.: Model procesa vezanih uz upis kolegija

Opis procesa vezanih uz izvođenje nastave

Inicijalni slijed procesa izvođenja nastave počinje procesom pripreme nastavnih materijala. Nastavni materijali objavljuju na sustavu za upravljanje nastavnim materijalima i e-učenje, čime postaju dostupni svim studentima upisanim na predmet. Akademski kalendar studijskog programa određuje plan i realizaciju nastave iz predmeta, a moguće inačice se mogu prepoznati kao semestralno izvođenje nastave ili izvođenje nastave u kraćim nastavnim ciklusima (turnusna nastava). S obzirom na raspored koji predstavlja plan izvođenja, provode se nastavne aktivnosti.

Studenti koriste nastavne materijale u sustavu za upravljanje e-nastavnim materijalima i čekaju ispitni rok iz predmeta. Prema planu ispitnih rokova studentu planiraju izlaske na ispite i pristupaju istim. Ako je student zadovoljio na ispitu, onda mu pozitivna ocjena određuje daljnji tijek odabira i upisa predmeta. Ako student nije zadovoljio, sukladno ugovorenim pravilima ponovno pristupa ispitnim rokovima. Drugi uvjet ostvarenja preduvjeta za ponovni ciklus odabira i upisa predmeta ili napredovanja u studiju može biti organizacija i odrađivanje praktičnog stručnog rada.

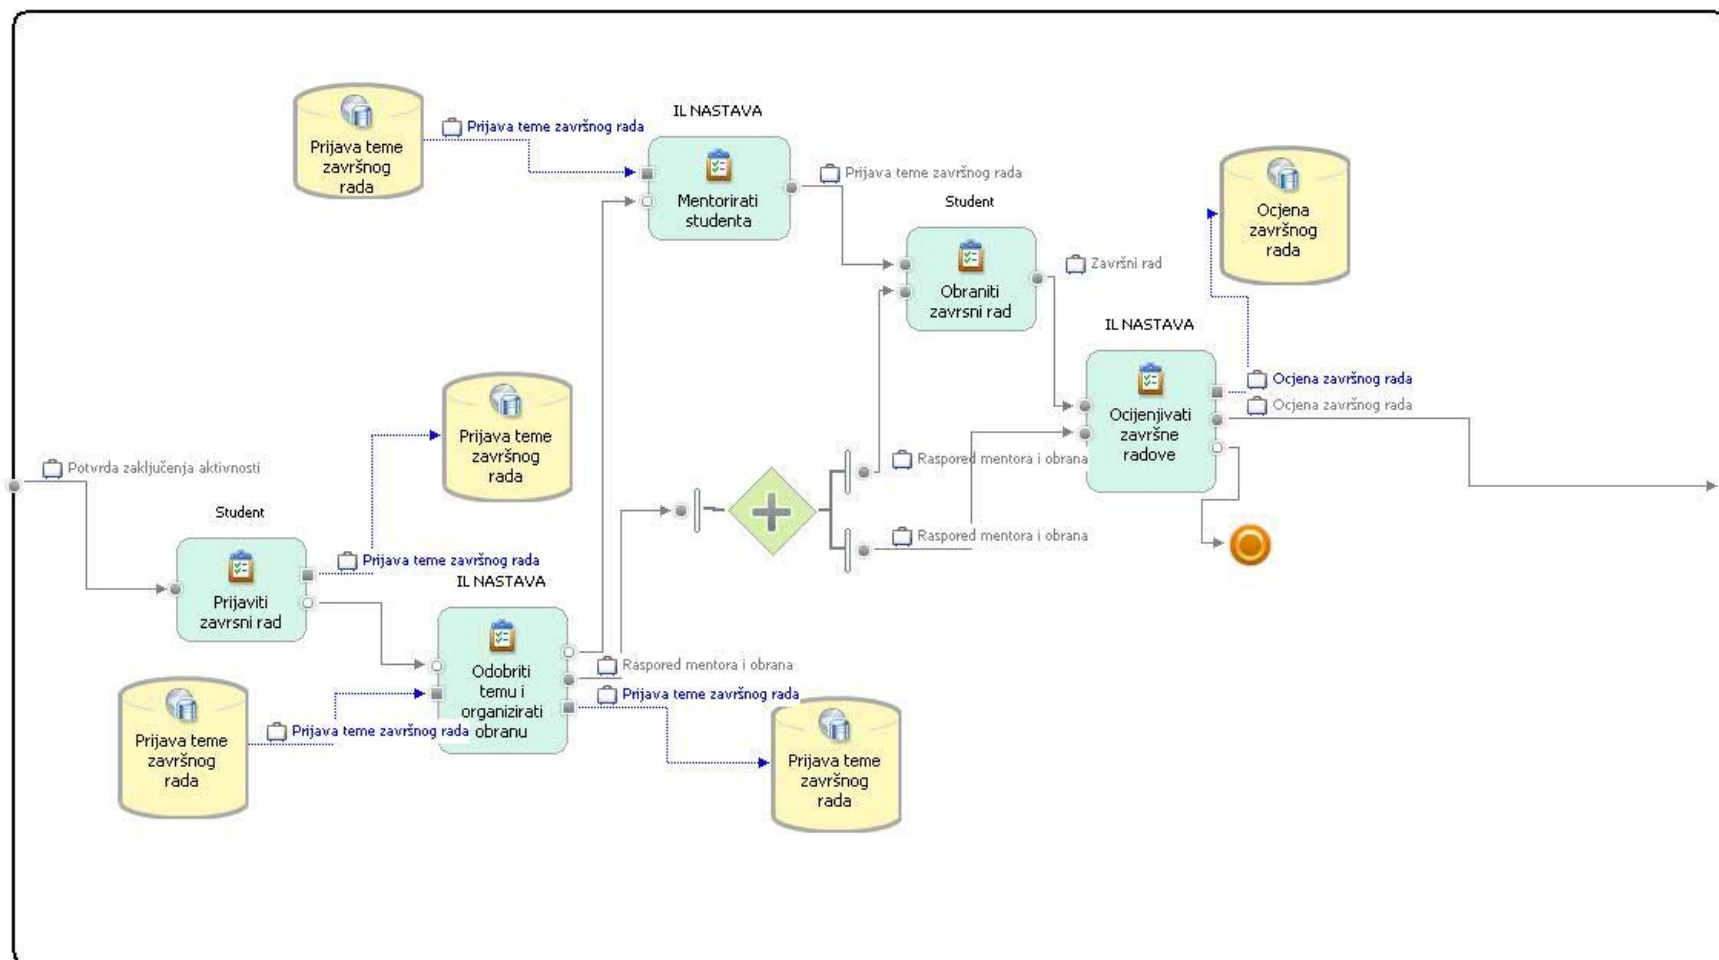


Slika 3.19.: Model procesa vezanih uz izvođenje nastave

Opis procesa vezanih uz vođenje završnih radova

Kada student prikupi dovoljan broj ECTS bodova i/ili zadovolji ostale kriterije koji mu potvrđuju zaključenje svih prethodno potrebnih aktivnosti onda može prijaviti završni rad. Vrsta studijskog programa određuje inačicu sljedećeg procesa: Odobravanje teme i organizacija obrane. Za završene radove preddiplomskog i diplomskog studija postupak odobravanja teme može biti realiziran preko katedri i implementiran u podsustav informacijskog sustava visokog učilišta.

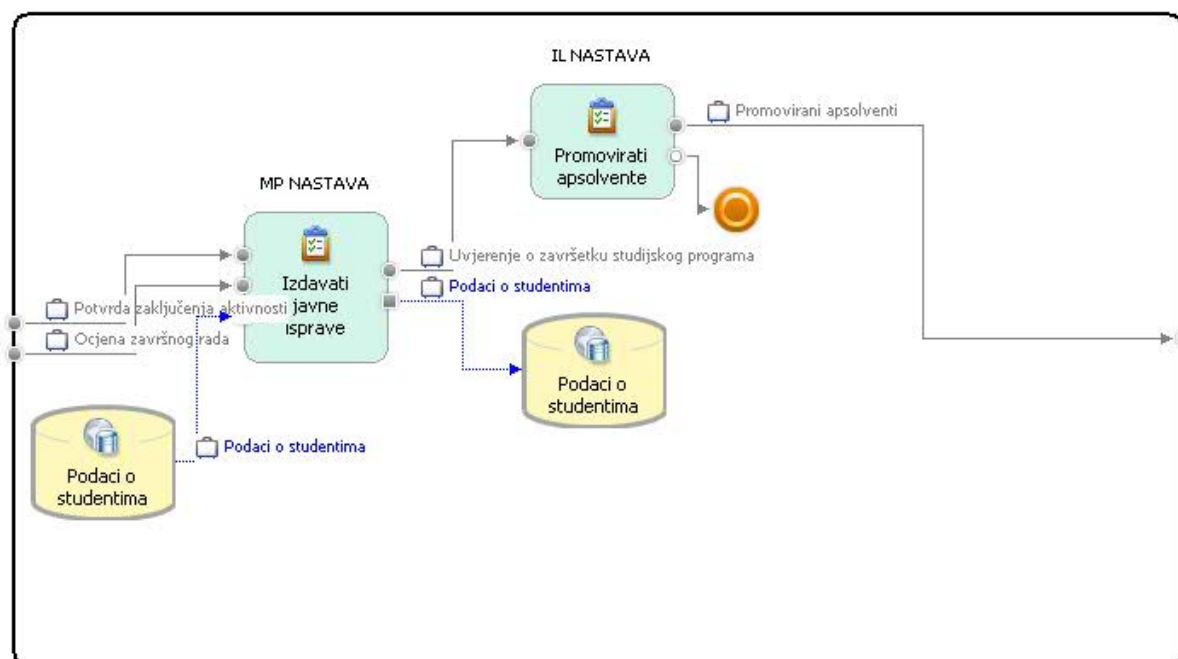
Postupak završnih radova viših programskih studija zahtijeva i uključivanje drugih tijela u postupak odobravanja teme kao što su Fakultetsko vijeće, Sveučilišni senat i/ili druga relevantna vijeća znanstvenika koji su kvalificirani za ocjenjivanje značaja rada. Nastavnik mentorira studenta pri izradi rada te sudjeluje u organizaciji i provedbi obrane i ocjenjivanja rada.



Slika 3.20.: Model procesa vezanih uz vođenje završnih radova

Opis procesa vezanih uz vođenje završnih radova

Na temelju potvrde zaključenja svih prethodnih aktivnosti definiranih nastavnim planom i programom studija na koji je student upisan, nadležno osoblje izdaje javne isprave o završetku studijskog programa. Organiziraju se i održavaju promocije apsolvenata.

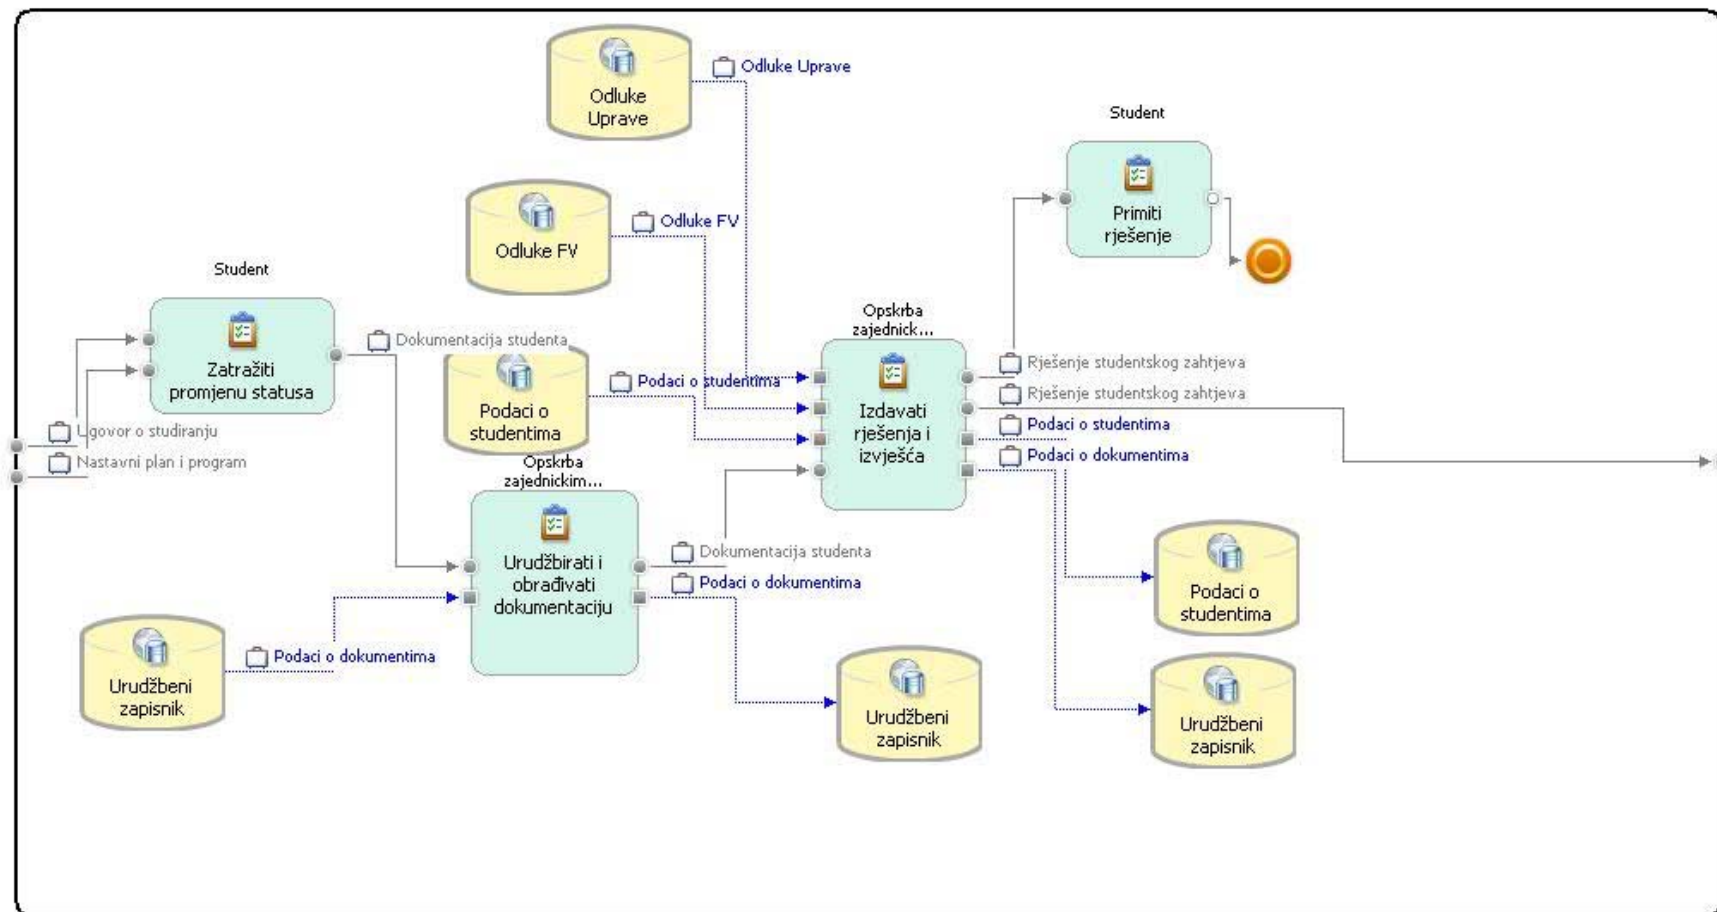


Slika 3.21.: Model procesa vezanih uz izdavanje diploma

Opis procesa vezanih uz rješavanje studentskih zahtjeva

Kod upisa studenta za studijski program, student i visoko učilište se obvezuju na određena prava i obveze. Tijekom studijskog „staža“, student može zatražiti promjenu određenog statusa (promjenu studijskog programa, promjenu odabira predmeta i slično).

Svaki zahtjev studenta se zaprima i pohranjuje u sustav za upravljanje dokumentacijom. Ovaj sustav je neophodan zbog pravnog statusa visokog učilišta, kao pravne osobe koja je ovlaštena izdavati javne isprave i rješenja. Promjena statusa može biti iniciran i po službenoj dužnosti, odnosno od tijela unutar visokog učilišta čime se regulira status studenta s obzirom na odluke upravljačkih tijela (Fakultetske uprave ili Fakultetskog vijeća).



Slika 3.22.: Model procesa vezanih uz rješavanje studentskih zahtjeva

Opis procesa vezanih uz upravljanje akademskim aktivnostima

Planiranje i upravljanje resursima visokih učilišta se najvećim dijelom realizira u upravljanju akademskim aktivnostima. Na temelju podataka o upisanim predmetima, o upisanim studentima, zaposlenicima i predviđenim normama rada, dostupnoj opremi i raspoloživim dvoranama, a prije početka nastave treba izraditi plan akademskih aktivnosti nastave, odnosno kraće: raspored. Prema rasporedu se izvode nastavne aktivnosti, a njihova realizacija se prati pomoću evidencije održane nastave.

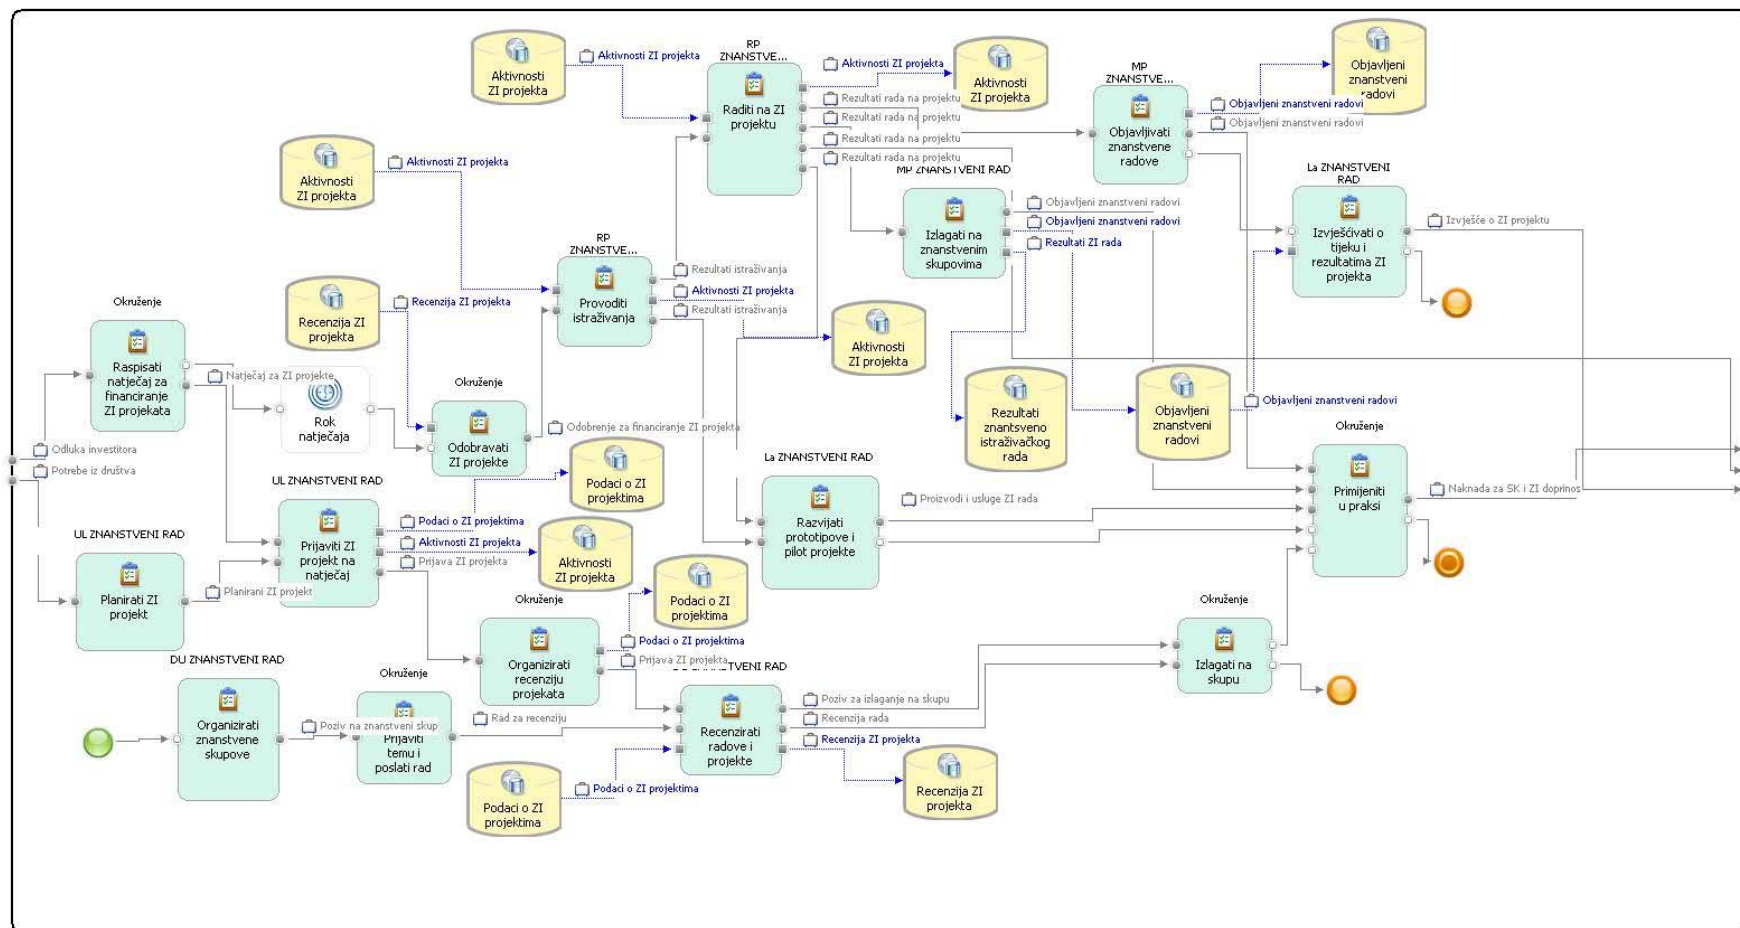
Usklađivanje opterećenja zaposlenika se provodi i s obzirom na planiranje i realizirane aktivnosti na znanstvenim i stručnim projektima. Raspoređivanje opterećenja zaposlenika utječe i proizlazi iz plana akademskog razvoja zaposlenika i realizacije plana kroz napredovanja u zvanjima.

Opis procesa vezanih uz rad na znanstveno istraživačkim projektima

Znanstvenici planiraju znanstveno istraživačke projekte i prate natječaje za financiranje. Na natječaje se šalju prijave projekata s podacima o planiranim aktivnostima projekta. Potencijalni financijeri znanstveno istraživačkih projekata analiziraju prikupljene prijave, organiziraju i omogućavaju recenziju prijava. Prema recenzijama projekata, projekti se odobravaju ili odbijaju.

Za odobrene projekte se operativno planiraju aktivnosti i sudionici na projektu. Rezultati rada na projektu se objavljuju kao znanstveni radovi i primjenjuju u praksi.

Drugi način sudjelovanja u znanstvenom radu jest kroz organizaciju i/ili sudjelovanje na znanstvenim skupovima. U tom slučaju se recenziraju pristigli radovi koji se izlažu na skupu.



Slika 3.24.: Model procesa vezanih uz rad na znanstveno istraživačkim projektima

Opis procesa vezanih uz rad na stručnim i komercijalnim projektima

Stručnjaci prate natječaje za stručne i komercijalne projekte na kojima mogu potvrditi znanstvene spoznaje i znanja stečena na znanstveno istraživačkim projektima. Na natječaje se šalju prijave projekata s podacima o planiranim aktivnostima projekta. Potencijalni financijeri stručnih i komercijalnih projekata analiziraju pristigle prijave, odabiru izvođača projekta.

Za ugovorene stručne projekte se operativno planiraju aktivnosti i sudionici na projektu. U sklopu rada na projektu se izrađuje proizvod ili usluga, čiji se prototip prezentira klijentu. Ako je klijent zadovoljan, rezultat rada se primjenjuje u praksi. Ako klijent ima primjedbe na predloženo rješenje, onda se daju specifikacije promjena te se projekt dorađuje. Rezultati rada na projektu se objavljuju kao stručni radovi i kao predložak rješenja primjenjuju u praksi.

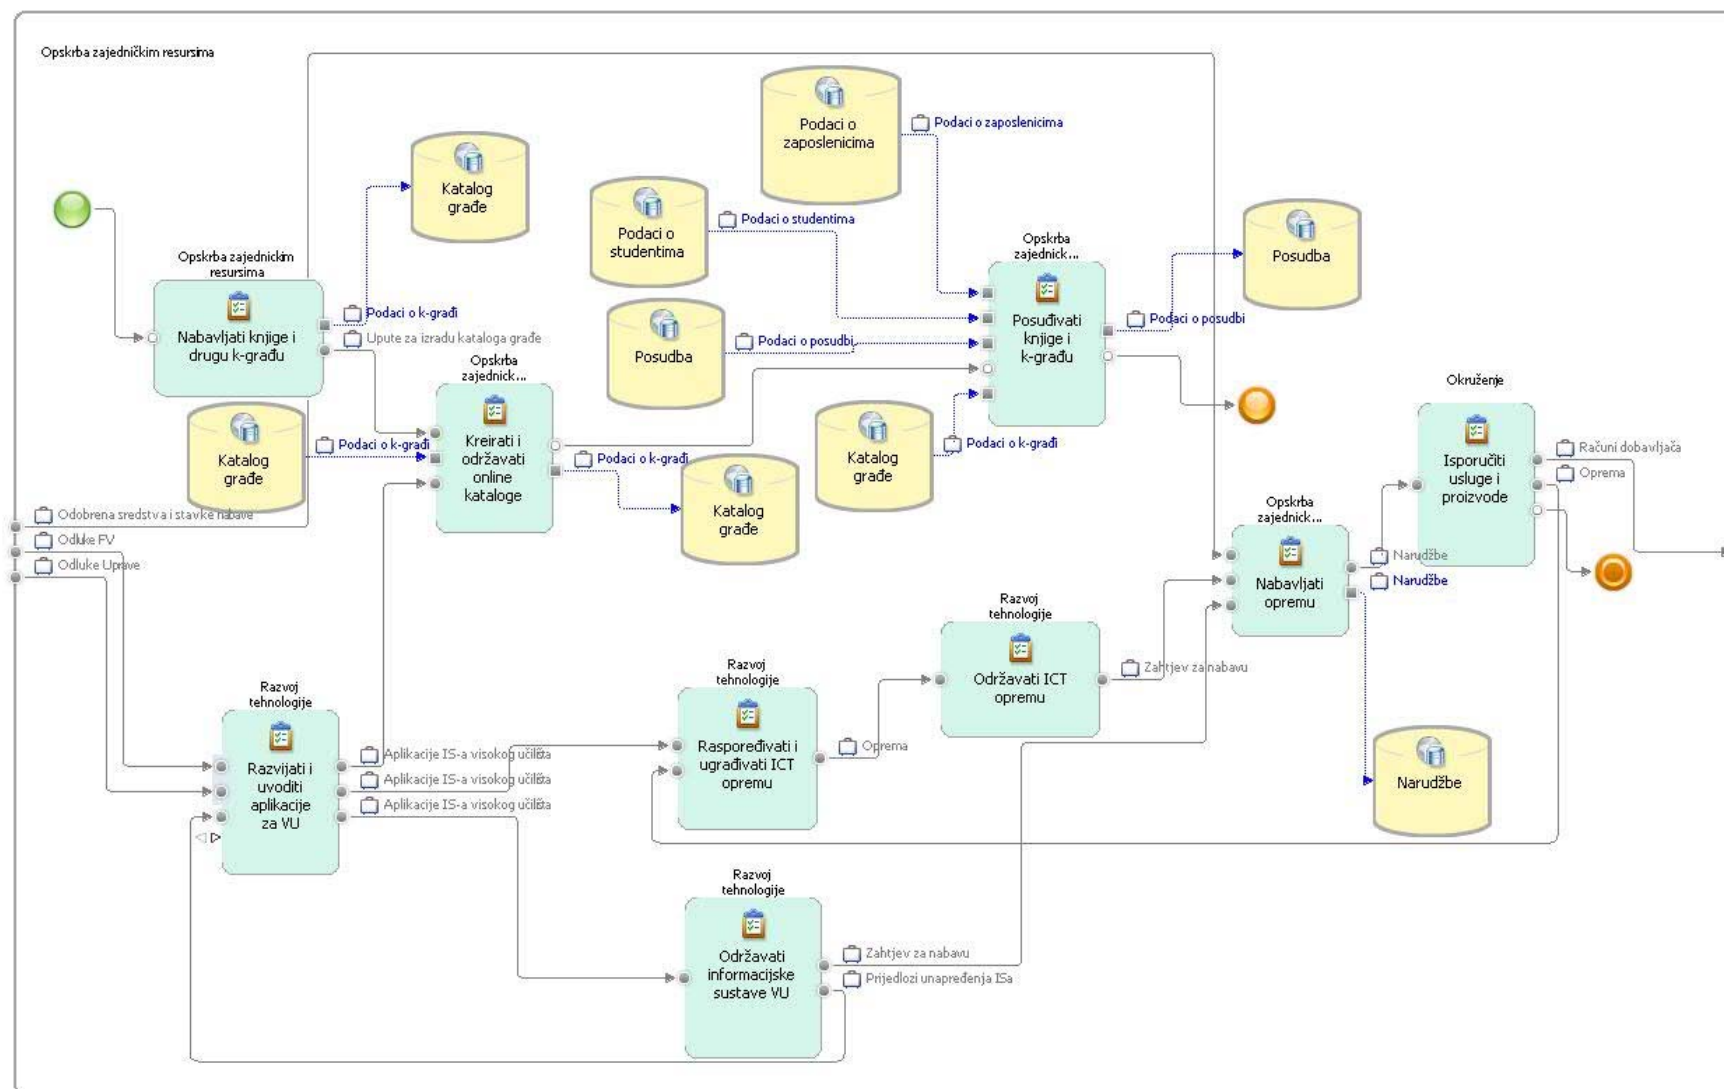
Drugi način transfera stručnog znanja u društvo je kroz organizaciju seminara i tečajeva.

Opis procesa vezanih uz opskrbu zajedničkim resursima

Jedna podgrupa procesa zajedničke opskrbe resursima se odnosi na poslove koji su vezani uz nabavu, katalogiziranje i posuđivanje stručne, znanstvene i nastavne literature. Ovi procesi se mogu detaljno modelirati kao zasebna cjelina, jer zapravo predstavljaju knjižničarsku djelatnost koja se provodi na visokim učilištima.

Druga podgrupa procesa se odnosi na razvijanje aplikacija i podatkovne infrastrukture informacijskog sustava visokog učilišta, raspoređivanje i održavanje ICT opreme.

Sva oprema (uključujući i ICT opremu) se nabavlja postupkom javne nabave. U modelu se pretpostavlja da se roba ne naručuje za skladište, već ide izravno u korištenje. Ako je u sklopu visokog učilišta implementirano i skladišno poslovanje, onda se ti procesi moraju dodati u postojeće modele.



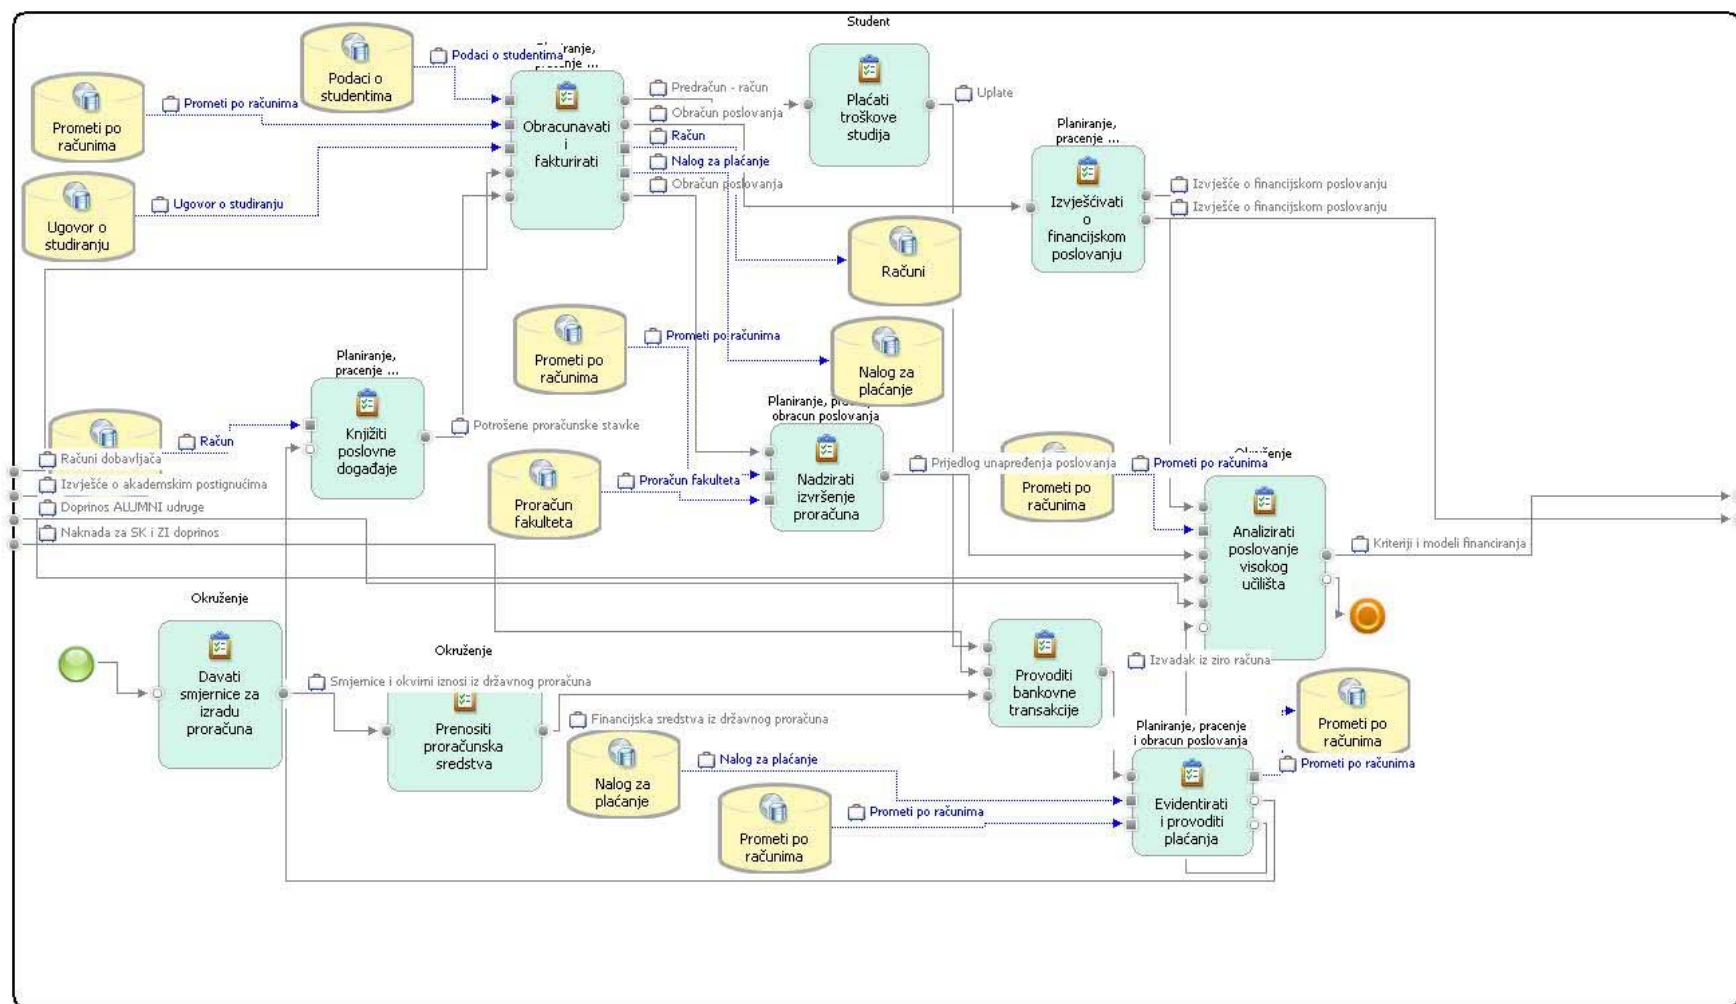
Slika 3.26.: Model procesa vezanih uz opskrbu zajedničkim resursima

Opis procesa vezanih uz upravljanje financijama

Iz okruženja visokog učilišta dolaze smjernice za izradu proračuna visokog učilišta (npr. planirana sredstva iz državnog proračuna i Sveučilišta). Proračunska sredstva se prema ugovorenoj dinamici prenose na račune visokih učilišta ili posredno na račun sveučilišta.

Računovodstvena organizacijska jedinica visokog učilišta knjiži poslovne događaje, obračunava i fakturira, naplaćuje i evidentira plaćanja. Tijekom proračunske godine se nadzire izvršenje planiranog proračuna, te se o tome izvješćuje okruženje koje analizira financijsko poslovanje visokog učilišta.

Za obračunata potraživanja i pristigle financijske obveze se provode plaćanja posredstvom poslovnih banaka i drugih financijskih institucija.



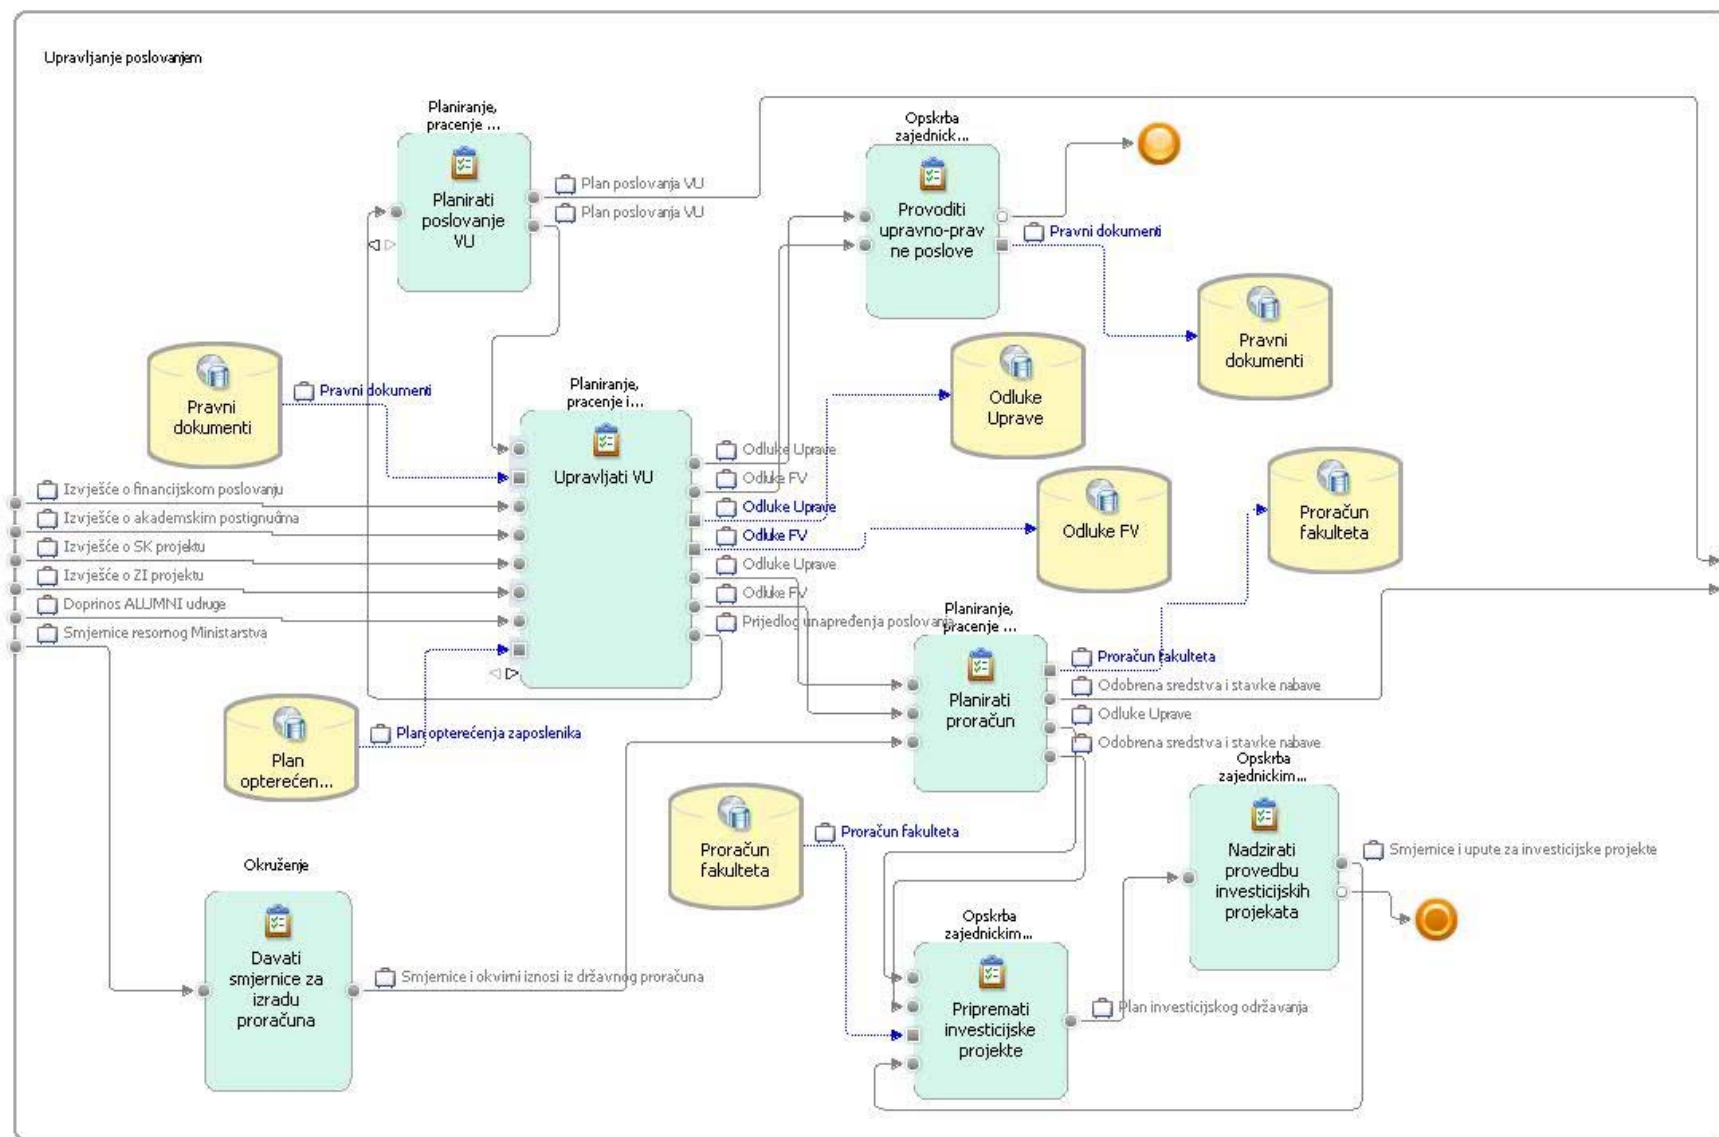
Slika 3.27.: Model procesa vezanih uz upravljanje financijama

Opis procesa vezanih uz upravljanje poslovanjem

Upravljačka tijela visokih učilišta planiraju poslovanje i upravljaju visokim učilištem. Iz operativnih organizacijskih jedinica dobivaju izvješća o radu i provedbi planiranih znanstvenih i stručnih projekata, te realizaciji nastavne djelatnosti i napredovanju u akademskim zvanjima.

Upravljanje poslovanjem obuhvaća i upravljanje osnovnim infrastrukturnim resursima, čiji se razvoj planira dugoročno, a realizira tijekom više mandata izbora upravljačkih tijela.

Sve upravljačke aktivnosti su određene proračunskim financijskim okvirom unutar kojeg treba planirati i nadzirati korištenje resursa visokih učilišta.



Slika 3.28.: Model procesa vezanih uz upravljanje poslovanjem

U ovom poglavlju su najprije dekompozicijom identificirani poslovni i akademski procesi visokih učilišta. Primjenom analize procesa s obzirom na značaj procesa u upravljanju resursima poslovanja i analize životnog ciklusa resursa provjerene je kompletnost popisa procesa. Zatim je analiziran značaj procesa u generiranju novih vrijednosti primjenom Porterovog modela. BCG analiza je dala prioritete i preporuke za informatizaciju procesa visokih učilišta. Nakon toga je izrađen prijedlog modela poslovnih i akademskih procesa visokih učilišta pomoću BPM notacije. Predloženi model treba usporediti s drugim referentnim modelima procesa za visoka učilišta, što će biti učinjeno u sljedećem poglavlju.

4. Usporedba novog modela s postojećim javno dostupnim modelima procesa visokih učilišta

U ovom poglavlju će najprije biti navedeni svi pronađeni postojeći javno dostupni modeli poslovnih procesa visokih učilišta, zatim će se definirati kriteriji analize odstupanja novog predloženog modela procesa visokih učilišta od ostalih javno dostupnih referentnih modela procesa visokih učilišta, te će se na kraju dati zaključak o tome može li se novi model smatrati referentnim modelom procesa visokih učilišta.

4.1. Postojeći javno dostupni modeli procesa visokih učilišta

U ovom potpoglavlju su prikazani svi pronađeni javno dostupni modeli procesa, različitih formi, iz različitih izvora: neki su nastali na visokim učilištima, neki su predstavljeni od dobavljača gotovih informacijskih sustava, dok za neke nije poznato s kojom svrhom su izrađeni, ali su odabrani i prikazani u radu jer na neki način prikazuju različite pristupe i razine detaljizacije kod izrade modela procesa. Postojanje različitih pristupa i razina detaljizacije u modeliranju procesa utvrdili su i potvrdili Merwe i Kotze [57] kada su istraživali pristupe identifikaciji referentnih modela.

4.1.1. Model procesa visokog učilišta Charles Sturt University

Visoko učilište Charles Sturt University iz Australije, nudi programe visokog obrazovanja na daljinu i klasične oblike obrazovanja u 7 kampusa. Visoko učilište CSU je na svojim službenim internetskim stranicama objavilo model procesa kojeg nazivaju referentnim modelom procesa visokih učilišta (*engl. Higher Education Process Reference Model*), a koji je razvijen sa svrhom analize i unapređenja vlastitih procesa [14].

Model predstavlja sveobuhvatan pregled procesa tog visokog učilišta, pri čemu su procesi razvrstani u sljedeće grupe procesa:

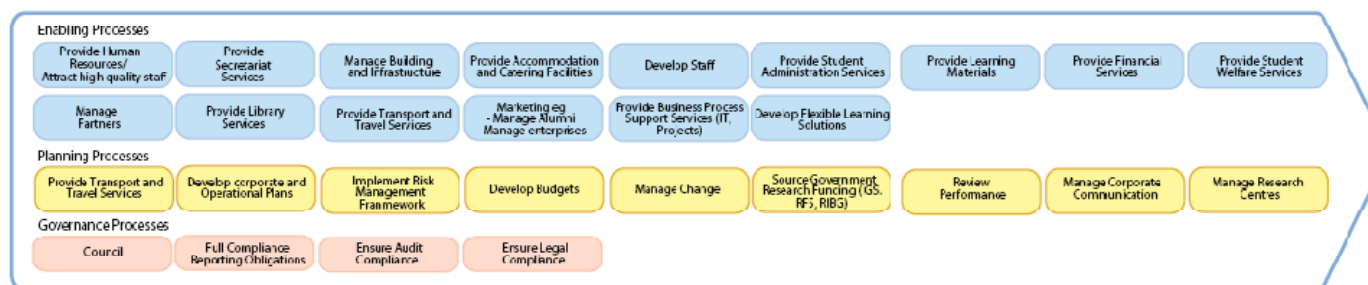
- Osnovni procesi (*engl. Core processes*):
 - Procesi odabira studija i upisa (*engl. Determine Course and Discipline Profile*),

- Procesi učenja i podučavanja (*engl. Learning and Teaching*),
- Procesi znanstvenog rada i poslijediplomskih studija (*engl. Research and Graduate Studies*);
- Potporni procesi (*engl. Support processes*):
 - procesi planiranja (*engl. Planning Processes*),
 - procesi upravljanja (*engl. Governance Processes*), te
 - uslužno-potporni procesi (*engl. Enabling processes*).

Model je prikazan na slici 4.1., a temelji se na razmatranju procesa prema lancima generiranja novih vrijednosti (tzv. Porterovom lancu vrijednosti).

CSU Process Model

Core process: LEARNING AND TEACHING




Slika 4.1.: Model procesa visokog učilišta Charles Sturt university

4.1.2. Model procesa visokog učilišta Glendale Community College

U članku Praksa inženjeringa procesa za visoka učilišta autora Bruno, Vrana i Welz [12], navodi se primjer mape procesa koledža u Glendaleu, Kalifornija. Autori su dali prikaz mape procesa na kojoj su prikazani glavni procesi visokog učilišta (autori koriste engleski termin „major processes“). Procesu su podijeljeni u tri grupe:

1. Procesi savjetovanja i potpore studentima kod administracije studija,
2. Procesi razvoja programa studija i predmeta, i
3. Potporni procesi.

U podnožju modela su autori prikazali veze prema dionicima kao što su dobavljači, tijela državne i javne uprave. Svaki od procesa unutar tri osnovne grupe bi se trebao modelirati detaljnije na zasebnom modelu, kako bi se osigurala preglednost modela i naglasio fokus na točno određenu grupu poslova. Model procesa je prikazan na slici 4.2.

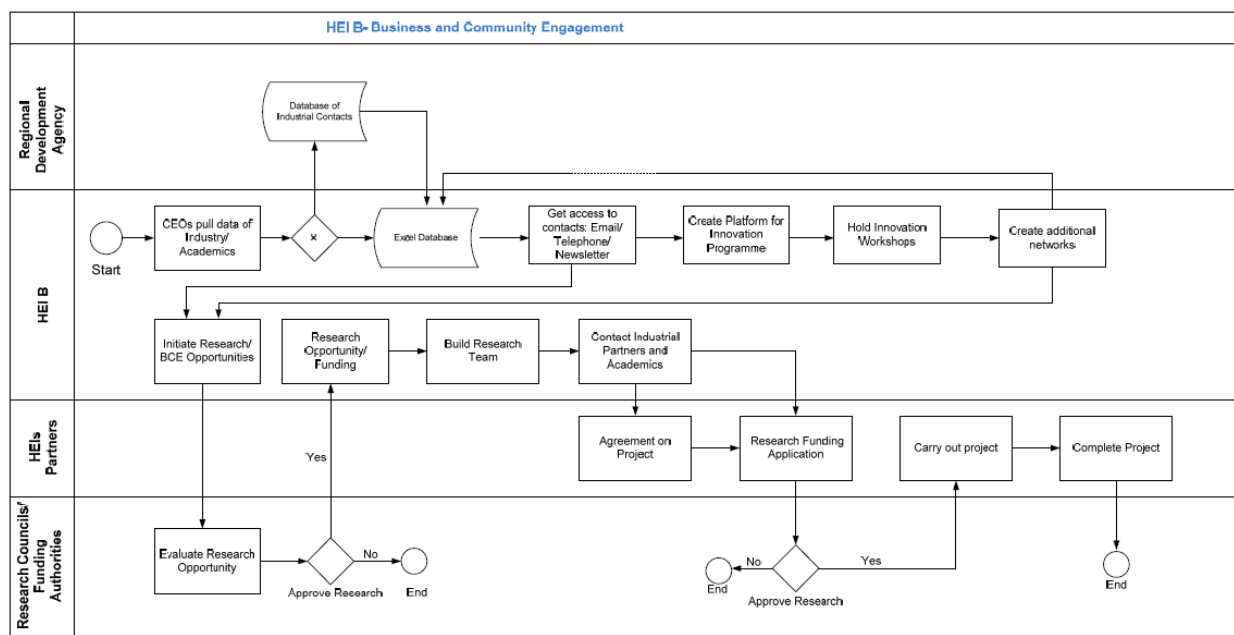


Slika 4.2.: Mapa procesa visokog učilišta Glendale Community College

4.1.3. Model procesa visokog učilišta prema JISC

JISC (skraćeno od *engl. Joint Information Systems Committee*) je tijelo kojeg financiraju visoka učilišta Ujedinjenog kraljevstva. JISC je zamišljen kao tijelo koje treba upravljati projektima vezanim uz primjenu novih tehnologija u visokom obrazovanju i znanstvenom radu [45].

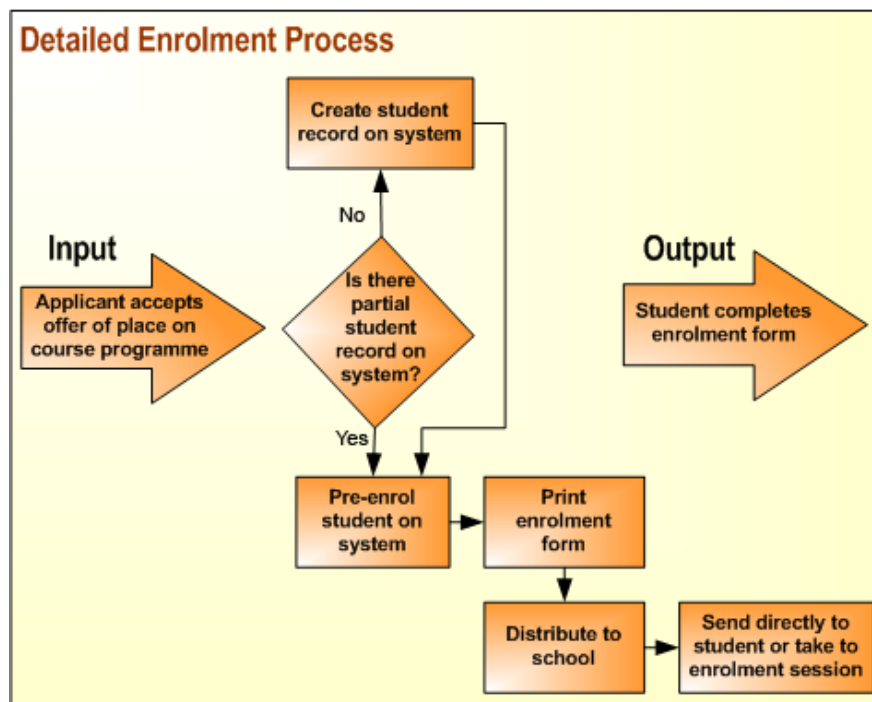
Prvi primjer modela je objavljen u studiji projekta analize procesa upravljanja odnosima s kupcima (*engl. CRM Processes: Self Analysis Tools*, [43]). Projekt je financiran od strane JISC, a modele su izrađivali polaznici doktorskog studija Sveučilišta u Nottinghamu. Studija obuhvaća nekoliko modela procesa za različite klase visokih učilišta (ukupno 9 klasa koje se odnose na različite tipove visokih učilišta, grupa institucija visokih učilišta). Model na slici 4.3. je naveden kao primjer modela iz studije, izrađen je prema UML-u, a odnosi se na radne aktivnosti visokog učilišta klase B u društvu i gospodarstvu.



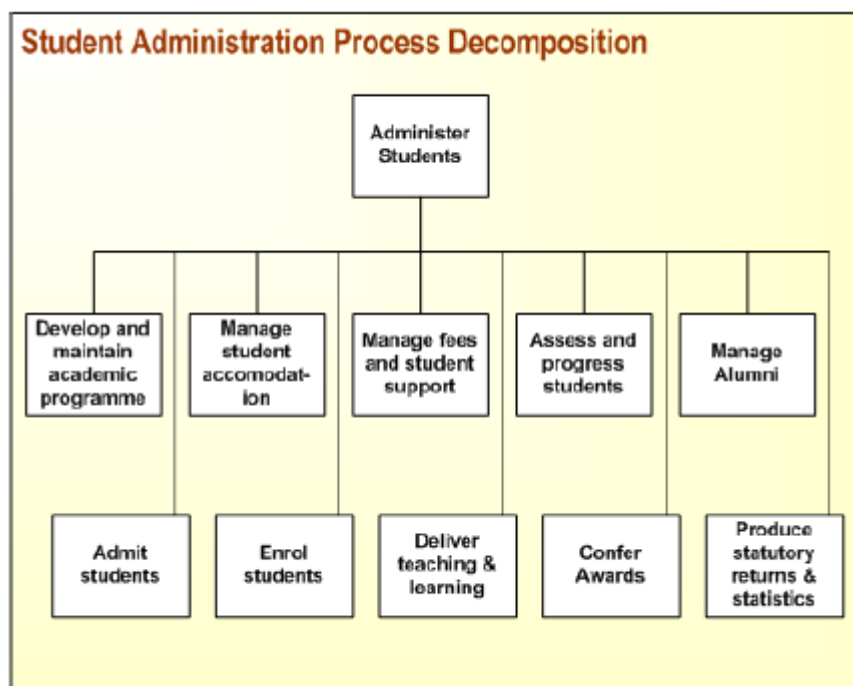
Slika 4.3.: Model CRM procesa Sveučilišta u Nottinghamu (verzija za instituciju klase B)

Sljedeće slike prikazuju primjere modela sa službenih internetskih stranica JISC-a koji neće biti uzeti u obzir kod usporedne analize, već su navedeni kao ilustracija dobre prakse pristupačnosti i transparentnosti procesa prema studentima. Model prikazan na slici 4.4., izrađen je prema IDEF0, a odnosi se na proces kojim student odabire predmet

na studiju. Model prikazan na slici 4.5. je dijagram dekompozicije, a odnosi se na akademske procese visokog učilišta prema studentima.



Slika 4.4.: Model procesa Odabir predmeta⁹



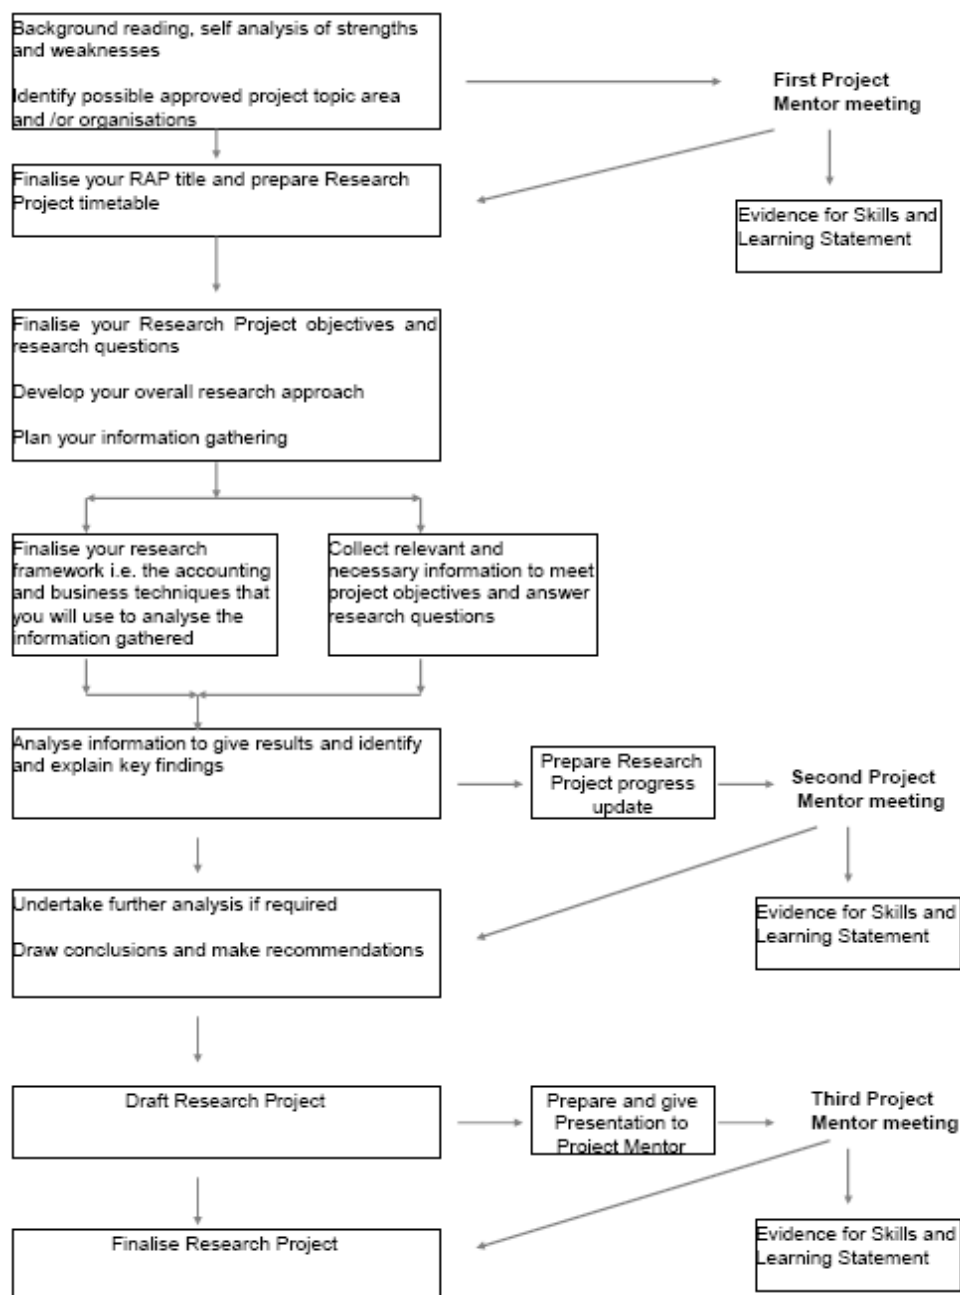
Slika 4.5.: Dijagram dekompozicije akademskih procesa prema studentima¹⁰

⁹ [44], <http://www.jiscinfonet.ac.uk/InfoKits/process-review/printable-version.pdf>

¹⁰ [42], <http://www.jiscinfonet.ac.uk/InfoKits/process-review/printable-version.pdf>

4.1.4. Model procesa vezanih uz znanstvene projekte visokog učilišta Oxford Brookes

Visoko učilište Oxford Brookes je prema engleskom vodiču kroz visoka učilišta časopisa Sunday Times (engl. *Sunday Times Good University Guide*) sedam godina zaredom bilo izabrano za najmodernije visoko učilište od svih Oxfordskih visokih učilišta. Oxford Brookes u svom vodiču za studente daje model procesa za znanstvene projekte. Model je prikazan na slici 4.6.

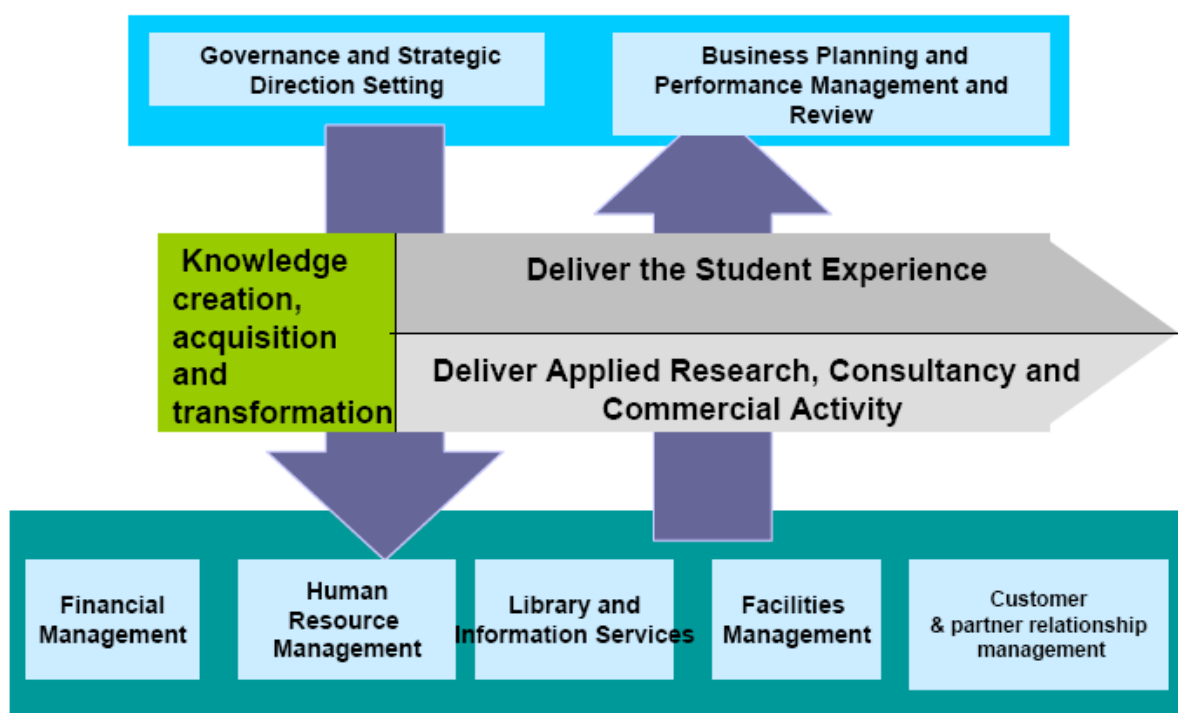


Slika 4.6. Model procesa za znanstvene projekte visokog učilišta Oxford Brookes¹¹

¹¹ [70] <http://www.accaglobal.com/documents/bscinfopack.pdf>

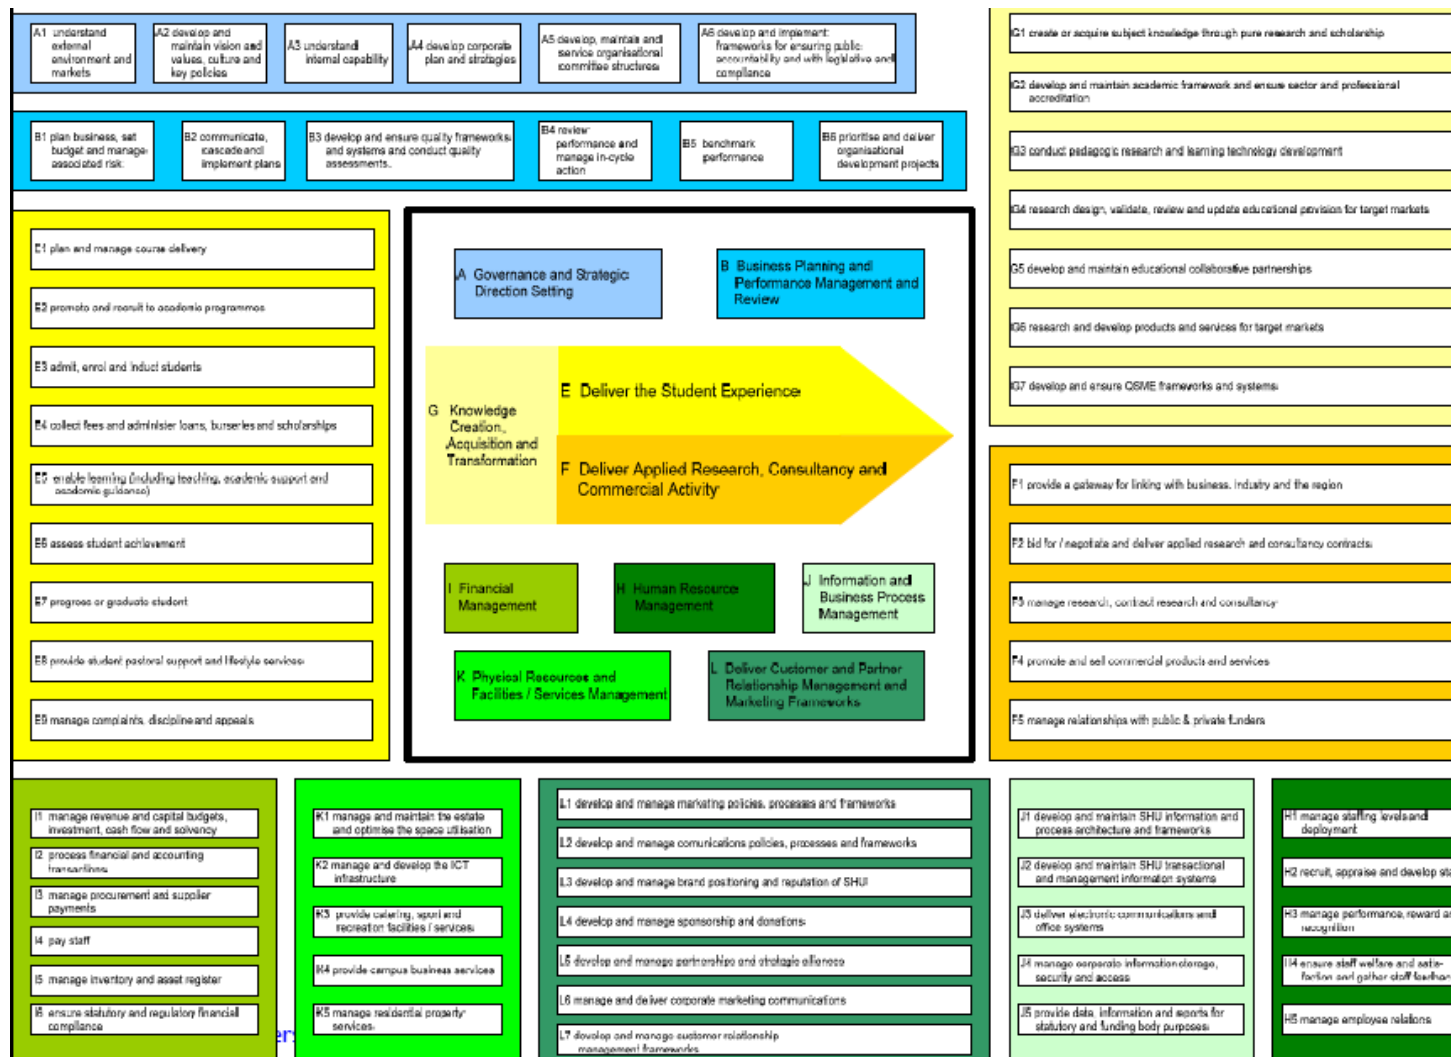
4.1.5. Procesi visokog učilišta Sheffield Hallam

U sklopu visokog učilišta Sheffield Hallam djeluje centar za individualni i organizacijski razvoj (nastao iz prijašnjeg centar integralnu izvrsnost *engl. Centre for Integral Excellence at Sheffield Hallam University*). Centar se bavi znanstvenim i komercijalnim projektima, a jedna od publikacija centra obuhvaća preglede procesa visokog učilišta Sheffield Hallam na razini grupa procesa i preglednoj detaljnoj razini. Budući da modeli nisu dostupni na službenim web-stranica visokog učilišta, oni nisu dio službene dokumentacije visokog učilišta, ali su odabrani i prikazani u ovom poglavlju zbog učestalog referenciranja modela autora modela Michaela Pupiusa [77]. Modeli su prikazani na slikama 4.7. i 4.8.



Slika 4.7.: Grupe procesa visokog učilišta Sheffield Hallam (Sheffield Hallam High Level Process Model)¹²

¹² [70], http://www.kodolanyi.hu/images/tartalom/File/hefop/quality2_mike_pupius.pdf



Slika 4.8.: Pregled procesa visokog učilišta Sheffield Hallam (Sheffield Hallam University Process Model v6)¹³

¹³ [70], http://www.kodolanyi.hu/images/tartalom/File/hefop/quality2_mike_pupius.pdf

4.1.6. Model procesa visokih učilišta mapiran sa SAP rješenjima

Modeli procesa koje nudi SAP kao jedan od proizvođača SAP sustava za visoko obrazovanje sadržani su u alatu za analizu i kompozitno projektiranje povezivanja modula SAP alata za potporu poslovanju pod nazivom „Solution composer“ dostupno na [86]. U alatu su dostupni modeli za:

1. Visoko obrazovanje (*engl. Higher Education*),
2. Istraživanje (*engl. Research*).

Na slikama 4.9. i 4.10. su prikazana stabla dekompozicije modula i aplikacija u alatu Solution Composer sa otvorenim granama sadržaja do razine procesa (npr. grana Higher Education>Student Lifecycle Management>Student Records>Admission to Program of Study).

Neki procesi su detaljnije opisani od drugih, kroz aktivnosti procesa sa tekstualnim opisom veza između tih aktivnosti. Iz sadržaja modela nije jasno po kojem kriteriju su odabrani procesi koji su detaljnije opisani. Primjer detaljnije opisanog procesa u alatu je prikazan na slici 4.11.

Na modelu procesa na slici 4.11. su prikazane samo aktivnosti bez naznake slijeda njihova izvođenja i bez naznaka sadržaja kojeg aktivnosti razmjenjuju tijekom izvođenja. Stoga je uz modele procesa naveden i kratki tekstualni opis slijeda aktivnosti, Opis slijeda aktivnosti procesa je u izvornom obliku prikazan iza slike 4.11.



Slika 4.9.: Dekompozicija modula i aplikacija za visoko obrazovanje u alatu Solution Composer



Slika 4.10.: Dekompozicija modula i aplikacija za istraživanje u alatu Solution Composer

ADMISSION TO PROGRAM OF STUDY

PROCESS VARIANT

Admission applications are processed according to the rules of the institution

Business Process

Admission To Program Of Study

Availability

● SAP Component or Feature Available

See also

- Admission to Program of Study

Process Steps



Admission to Program of Study

Purpose

You use this business process to associate a student's application with a program of study. An assessment process can be used to verify if the student possesses the relevant qualifications, documents and references required for the programs to which he or she has applied. Admission applications have the benefit of being status driven, providing institutions with the ability to use those statuses in follow up processes and for reporting purposes.

Prerequisites

If you use admission audits, proceed as follows:

- Activate *Use Assessment Process* indicator for relevant programs of study
- Define admission requirements

Process Flow

1. Create admission application
Create admission application for program of study (application status: "created").
2. Check admission requirements
Check admission requirements (references, prerequisite qualifications, and so on).
3. Execute admission audit
If you use admission auditing, execute admission audit to determine whether all requirements have been met.
4. Approve or reject
Approve or reject admission based on audit results (application status: "approved" or "rejected/withdrawn" – along with relevant status supplement).
5. Withdraw application
Withdraw application based on student's instructions (application status: "rejected/withdrawn" – along with relevant status supplement).

Result

Business process result

You have admitted the student to the program of study.

Follow-up process

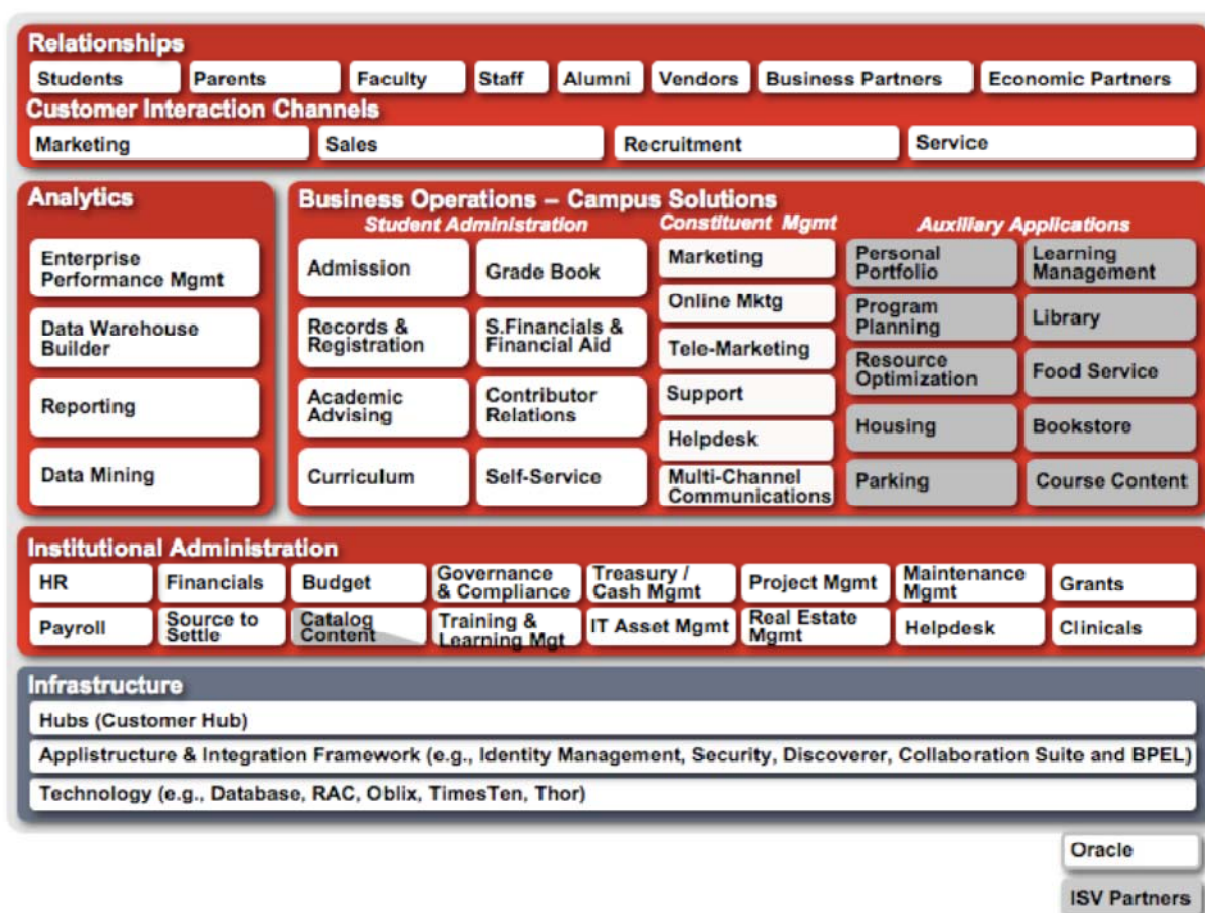
Register student for program of study.

Slika 4.11.: Model procesa za proces Upis na studijski program

4.1.7. Procesi visokih učilišta prema modulima Oracle ERP rješenja

Drugi primjer prikaza modula dobavljača ERP sustava za visoka učilišta je model poduzeća Oracle. Prikaz je objavljen na službenim web stranicama [69]. Prikaz nije model procesa, ali se iz naziva modula na prikazu može analizirati koje procese bi moduli trebali podržavati. U tom smislu se prikaz može koristiti za analizu jesu li proizvođači ERP alata prepoznali što sve ERP sustav za visoka učilišta mora podržavati. Prikaz je dan na slici 4.12.

Oracle's Footprint for Higher Education



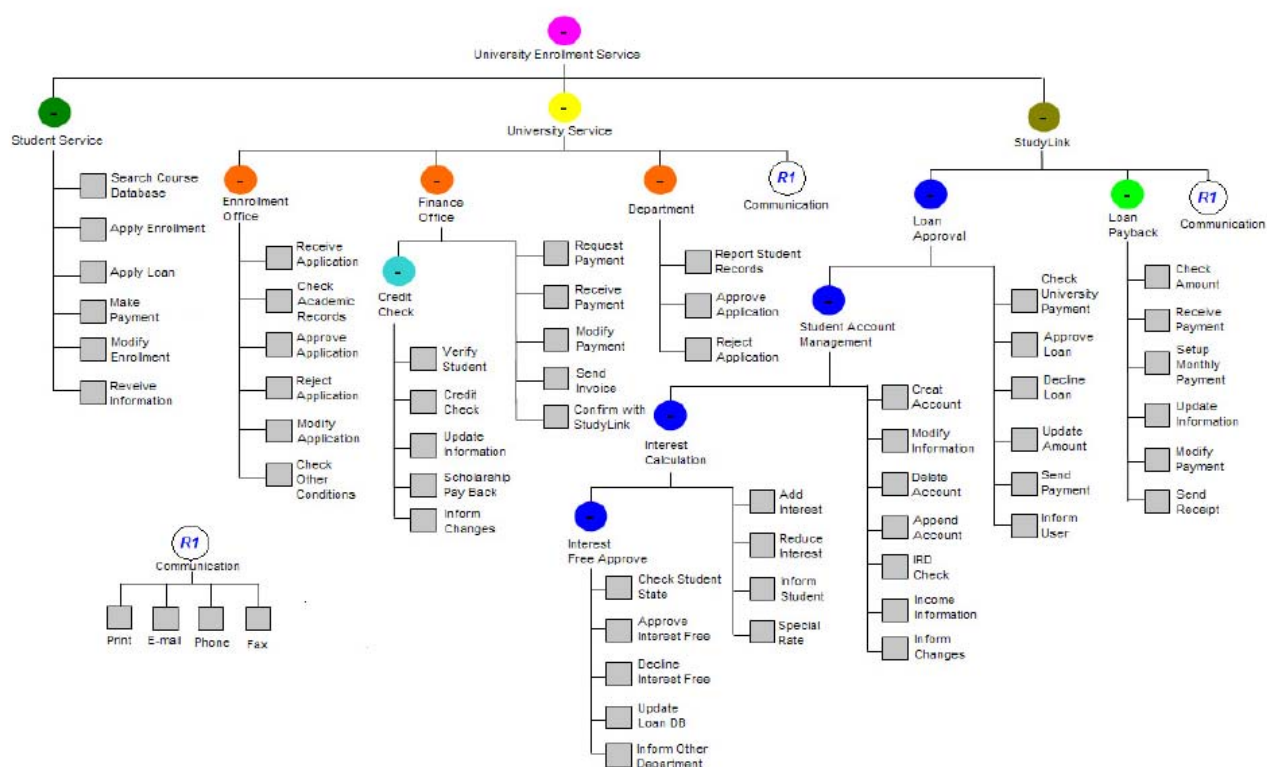
Slika 4.12.: Prikaz modula ERP sustava proizvođača Oracle¹⁴

Moduli ERP sustava trebaju podržavati procese upravljanja odnosima s kupcima i dobavljačima, procese poslovnog izvješćivanja i analize podataka, procese upravljanja kampusom i zapisima o studentima, administrativne procese, procese upravljanja kadrovima, procese upravljanja financijama i imovinom.

¹⁴ [69], www.oracle.com

4.1.8. Model procesa upisa na visoko učilište – pristup vizualnog modeliranja složenih procesa







Sljedeći primjer se odnosi na detaljni model procesa upisa na visoko učilište, nije klasični model procesa, ali je odabran zbog ilustracije različitih pristupa modeliranju procesa. Model na slici 4.13. prikazuje strukturu aplikativnih servisa ERP sustava, a slika 4.14. jedan mogući slijed aktivacije aplikacijskih servisa prilikom upisa na predmet od strane studenta.



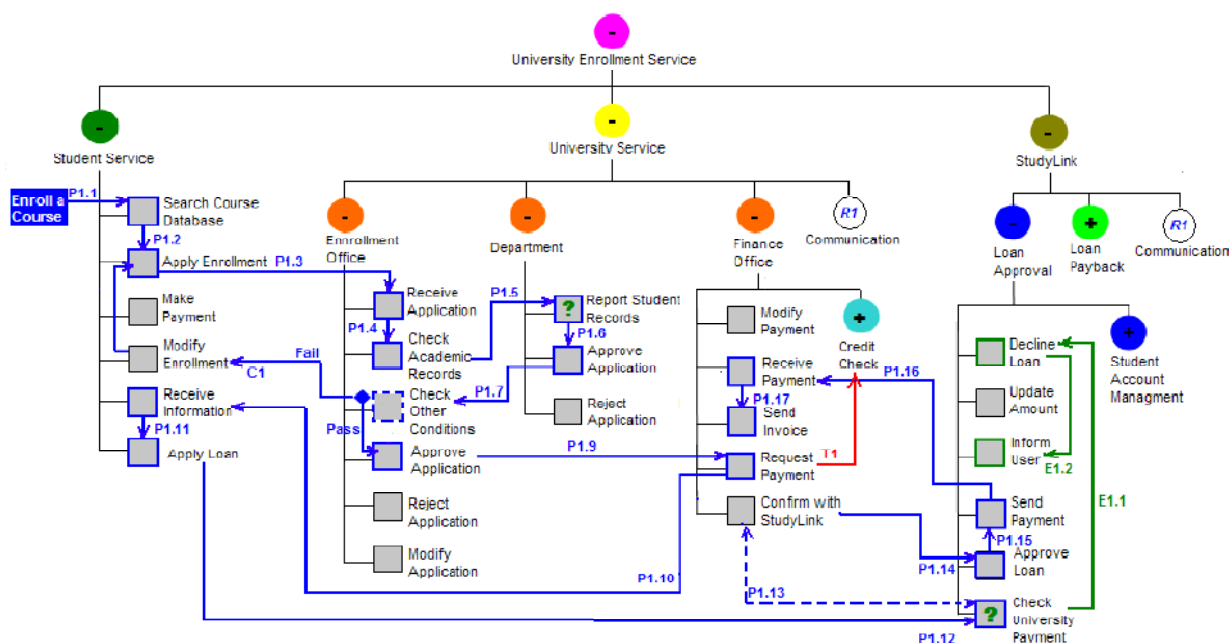
Slika 4.13.: Struktura aplikacijskih servisa ERP sustava visokog učilišta prema Li et.al.[52]

Autori Li et.al. su razvili jezik poslovnog modeliranja (Enterprise modeling language, EML) koji obuhvaća najmanje dvije razine prikaza: razinu prikaza strukturnog stabla aplikacija i razinu prikaza slijeda aktivnosti. Na razini prikaza strukturnog stabla je moguće modelirati strukturu aplikacija s ponavljanjem elemenata (npr. R1 je ponovno upotrebljiva komponenta, engl. Reusable), te otvarati i zatvarati grane radi sažetije forme stabla („+“ ili „-“, znak unutar čvora u grani). Razina prikaza slijeda aktivnosti obuhvaća elemente za prikaz aktivnosti:

-  obavezna aktivnost,

-  petlja u kojoj se izvodi samo jedna aktivnost tako dugo dok uvjet C1 nije zadovoljen,
-  vrata grananja ili spajanja,
-  tok normalnog slijeda,
-  tok iznimnog slijeda,
-  tok okidača paralelnog slijeda ili neke druge ovisne aktivnosti ,
-  tok koji omogućava spajanje više aktivnosti u jednu logičku petlju.

Na slici 4.14. je primjenom EML-a prikazano kako se aktiviraju aplikacijski servisi prateći slijed aktivnosti procesa, odnosno kako se koriste pojedinačni servisi za potporu izvođenja aktivnosti.



Slika 4.14.: Model procesa upisa na visoko učilište prema Li et.al.[52]

Pristup kojeg su predložili autori Li et.al. predstavlja dobar način povezivanja ili „mapiranja“ aplikacija i aktivnosti procesa, ali ujedno predstavlja i posebnu temu za daljnje istraživanje.

4.2. Usporedna analiza modela procesa

Postojeći javno dostupni modeli procesa iz prethodnog potpoglavlja su prikupljeni radi analize odstupanja novog predloženog modela visokih učilišta s postojećim modelima. Međutim, analizu odstupanja nije moguće provesti zbog **nedostupnost nekih modela**

referenciranih u literaturi¹⁵ i/ili nepostojanja detaljno opisanog cjelovitog referentnog modela procesa visokih učilišta s kojim bi se novi model mogao uspoređivati. Zaključak dosadašnjih istraživanja jest da su javno dostupni modeli usmjereni na pojedinačne procese ili proizvoljno grupirane procese studentske administracije, upravljanja kadrovima i upravljanja financijama visokih učilišta i kao takvi se mogu smatrati referentnim za posebne slučajeve analize specifičnih izoliranih procesa visokih učilišta u određen svrhe.

Umjesto analize odstupanja provesti će se usporedna analiza novog predloženog modela procesa visokih učilišta i javno dostupnih modela procesa visokih učilišta iz potpoglavlja 4.1.1. do 4.1.8. Usporedna analiza modela procesa će omogućiti pozicioniranje novog modela po ključnim kriterijima i određivanje referenci primjene.

Kriteriji su definirani tako da se ne analizira isključivo sadržaj modela, već i format i opseg modela.

Tablica 4.1.: Kriteriji usporedbe modela procesa

	Kriterij	Opis
Format	Primijenjena neka formalna notacija	Je li u izradi modela primijenjena neka formalna notacija ili metoda modeliranja procesa?
	Primijenjena BPMN	Je li u izradi modela primijenjena BPMN?
Opseg	Naznačen slijed izvođenja procesa	Je li na modelu prikazan slijed izvođenja procesa/aktivnosti?
	Navedeni ulazni sadržaji	Jesu li na modelu prikazani ulazni sadržaji potrebni za izvođenje procesa/ aktivnosti?
	Navedeni izlazni sadržaji	Jesu li na modelu su prikazani izlazni sadržaji koje proces/aktivnost generira?
	Model obuhvaća sve procese visokog učilišta	Prikazuje li model cjelovit skup svih poslovnih procesa visokog učilišta, grupu procesa ili jedan proces?
	Model podrazumijeva primjenu ICT	Podrazumijeva li model primjenu informacijskih i komunikacijskih tehnologija za potporu izvođenja procesa, odnosno može li se to prepoznati na modelu?

Predloženi model i ostali modeli iz poglavlja pregleda postojećih modela su analizirani po spomenutim kriterijima, a rezultati su prikazani u tablici 4.2. Razina zadovoljenja kriterija je opisana tekstualno, osim u slučaju kada kriterij nije primjenjiv ili kada se ne može procijeniti razina zadovoljenja kriterija.

¹⁵ Erica Wagner istražuje ulogu sustava planiranja i upravljanja resursima u modernizaciji akademske administracije te sa Sue Newell problematizira primjenu modela najbolje prakse u visokim učilištima [94]. Autorice navode primjer modela najbolje prakse kojeg su razvili proizvođači ERP sustava i grupa sveučilišta (Ivy-Vision grupa) koji još uvijek nije u potpunosti implementiran te se Ivy grupa još uvijek bori sa promjenom organizacije i reinženjeringom procesa.

Tablica 4.2.: Usporedna analiza modela procesa

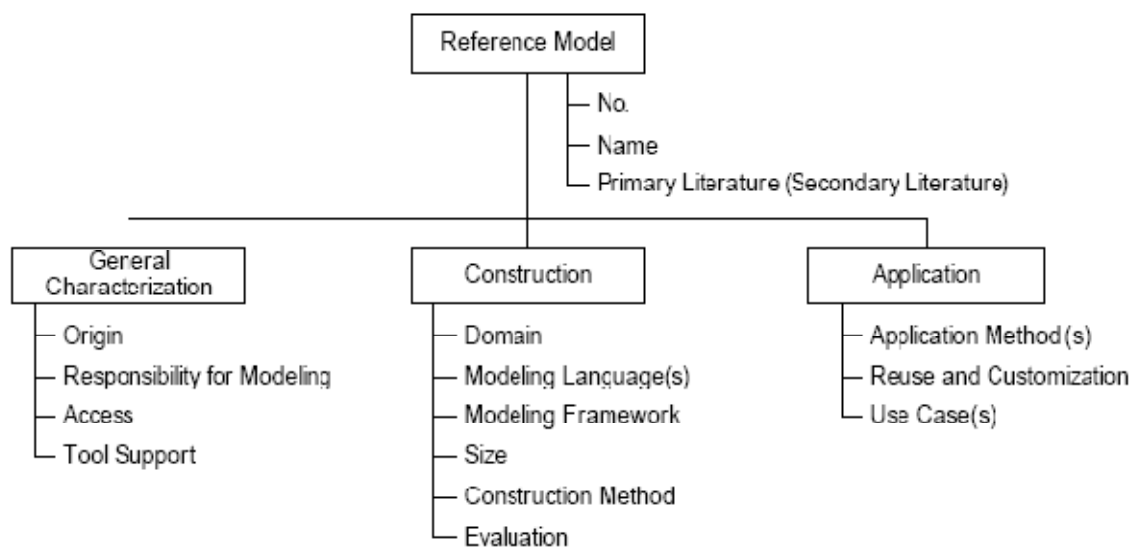
Kriterij	Model poslovnih i akademskih procesa	Model sveučilišta Charles Sturt	Model Glendale Community College	Modeli procesa JISC	Model procesa Oxford Brookes	Model procesa Sheffield Hallam	Model procesa SAP	Model procesa Oracle	Model procesa – vizualno modeliranje
Primijenjena neka formalna notacija	Da, BPMN	Da, Porterov lanac vrijednosti	Da, opisana u članku	Da, UML ili IDEF0	Nepoznato	Nepoznato	Nepoznato	Nije primjenjivo	Da, opisana u članku
Primijenjena BPMN	Da	Ne	Ne	Da	Nepoznato	Nepoznato	Ne	Nije primjenjivo	Ne
Naznačen slijed izvođenja procesa	Da	Djelomično, za grupe procesa	Da	Da	Da	Slijed se nazire za neke grupe procese	Djelomično, kroz tekstualne opise uz modele	Ne	Da
Navedeni ulazni sadržaji	Da, pridruženi ulaznim tokovima	Nije primjenjivo	Ne	Ne	Ne	Ne	Djelomično, kroz tekstualne opise uz modele	Nije primjenjivo	Nije primjenjivo
Navedeni izlazni sadržaji	Da, pridruženi izlaznim tokovima	Nije primjenjivo	Ne	Ne	Ne	Ne	Djelomično, kroz tekstualne opise uz modele	Nije primjenjivo	Nije primjenjivo
Model obuhvaća sve procese visokog učilišta	Da	Da	Nije primjenjivo	Ne, uz ograničenje da su modelirani pojedinačni procesi	Ne, model se odnosi na procese vezane uz znanstvene projekte	Ne, model se odnosi samo na poslovni aspekt djelovanja VU	Uglavnom da	Uglavnom da	Ne, uz ograničenje da su modelirani pojedinačni procesi
Model podrazumijeva primjenu ICT	Da, prikazano repozitoriji ma	Nepoznato	Nepoznato	Djelomično, modeli podrazumijevaju primjenu odgovarajućeg modula ERP-a	Nepoznato	Djelomično, modeli podrazumijevaju primjenu odgovarajućeg modula ERP-a	Da, model podrazumijeva primjenu modula ERP sustava VU	Da, model podrazumijeva primjenu modula ERP sustava VU	Da, model podrazumijeva primjenu modula ERP sustava VU

4.3. Osvrt na hipotezu mogućnosti izrade referentnog modela planiranja i upravljanja resursima visokih učilišta

Početna hipoteza je glasila: „Moguće je napraviti referentni model planiranja i upravljanja resursima koji je specifičan za visoka učilišta, s naglaskom na znanstveno istraživačku i nastavnu komponentu.“ Da bi se ova hipoteza dokazala bilo je potrebno najprije analizirati visoka učilišta kao organizaciju koja ima vlastite specifične akademske procese i poslovne procese koji se osiguravaju rad visokog učilišta kao svakog organiziranog poslovnog subjekta. Nakon toga su identificirani procesi modelirani primjenom odgovarajuće metode BPMN. Zatim je novi predloženi model akademskih i poslovnih procesa visokih učilišta uspoređen sa postojećim javno dostupnim referentnim modelima procesa visokih učilišta.

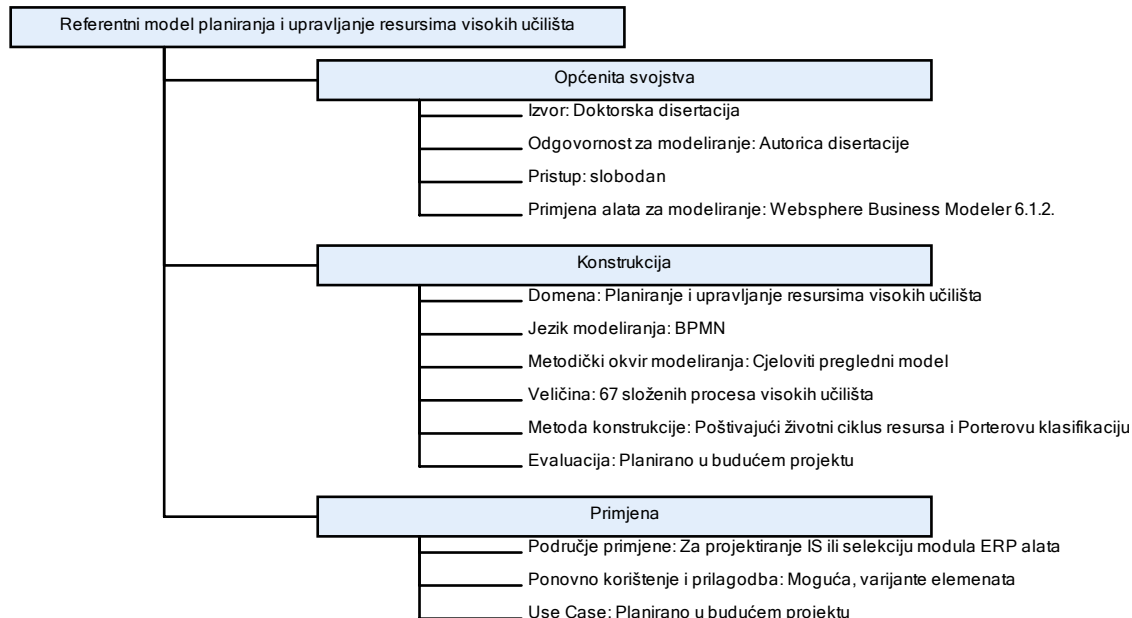
Iz rezultata usporedne analize modela možemo zaključiti da novi predloženi model poslovnih i akademskih procesa visokih učilišta ima određene prednosti u odnosu na svaki pojedinačni postojeći model, iako pojedinačno gledajući svaki postojeći model zadovoljava neke kriterije usporedbe jednako dobro kao i novi predloženi model iz poglavlja 3. Nakon usporedbe se ne može zaključivati o tome da li je novi model poslovnih i akademskih procesa bolji ili lošiji od postojećih modela, ali je sigurno detaljniji i omogućava razumijevanje poslovnih i akademskih procesa visokih učilišta na specifičan način.

Prema Fettke et.al. [31], referentni modeli procesa se mogu opisati pomoću kriterija prikazanih na slici 4.15. koji dovoljno dobro opisuju referentne modele procesa.



Slika 4.15. Kriteriji za opis referentnih modela [31]

Koristeći kriterije autora [31], na slici 4.16 su opisane karakteristike novog modela procesa visokih učilišta.



Slika 4.16.: Svojstva modela poslovnih i akademskih procesa visokih učilišta

Model poslovnih i akademskih procesa visokih učilišta je izrađen na specifičan način jer nudi cjelovit pregled procesa planiranja i upravljanja ključnim resursima visokih

učilišta, s naznačenim ulaznim i izlaznim podacima koji se vode u informacijskom sustavu. Svaki proces može imati svoje varijante izvođenja, što se očituje u detaljnom modelu svakog procesa, ne narušavajući pri tom ulazne i izlazne tokove. Model se može koristiti za pregled, planiranje, analizu i upravljanje načinom korištenja resursa u visokim učilištima.

Predloženi model akademskih i poslovnih procesa visokih učilišta, prikazan na slikama 3.15. do 3.28., opisan svojstvima na slici 4.16., zadovoljava definiciju referentnog modela planiranja i upravljanja resursima koji je specifičan za visoka učilišta, s naglaskom na znanstveno istraživačku i nastavnu komponentu.

5. Sustavi planiranja i upravljanja resursima

Nakon što su identificirani poslovni i akademski procesi visokih učilišta valja analizirati, istražiti i predložiti strukturu informacijskog sustava planiranja i upravljanja resursima koji treba podržavati te procese. Informacijski sustav za potporu procesima visokog učilišta (kao i svaki drugi informacijski sustav) može nastati na dva načina: 1. projektiranjem i razvojem informacijskog sustava prema organizacijskom sustavu ili 2. uvođenjem gotovog rješenja projektiranom i razvijanom prema generičkom organizacijskom sustavu. U ovom radu će se istražiti struktura i koncepti gotovih rješenja ili takozvanih ERP sustava (*engl. Enterprise Resource Planning Systems, ili kraće ERP sustavi*) za visoka učilišta. Iz tog razloga će se u ovom poglavlju rada najprije dati pregled definicija ERP sustava, zatim razmotriti neke odabrane klasifikacije ERP-ova, navesti neke metodike uvođenja ERP sustava te navesti preporuke najbolje svjetske prakse uvođenja ERP sustava za visoko obrazovanje.

5.1. Definicija ERP sustava

Postoje različite definicije pojma ERP sustav, a u nastavku su navedene neke definicije ERP sustava.

Prema Strahonji [84], definicija ERP sustava proizlazi iz njegove funkcije, odnosno ERP sustav je informacijski sustav koji zadovoljava sljedeće kriterije: podržava minimalno tri međusobno povezane poslovne funkcije, namijenjen je određenom tipu organizacije (*engl. Enterprise*), omogućava upravljanje resursima organizacije (*engl. Resources*) kroz planiranje i praćenje ostvarenja plana (*engl. Planning*).

Prema Vrčeku i Brumecu [92], ERP sustav je „skup logički povezanih programa koji rade nad jedinstvenom bazom podataka i podržavaju poslovne procese u organizaciji, ... nije razvijan za neku određenu organizaciju, prema svojim funkcijama je općenit, ali ujedno i prilagodljiv specifičnim potrebama većine organizacija sa srodnom djelatnošću“.

Prema O'Learyu [68], ERP sustavi su računalni sustavi za provedbu poslovnih transakcija i integraciju poslova planiranja, proizvodnje i komunikacije s kupcima u realnom vremenu. Između ostalog, ERP sustavi omogućavaju integraciju većine

poslovnih procesa organizacije, rade nad jedinstvenom bazom podataka, te omogućavaju unos i pristup podacima u stvarnom vremenu.

Definicijom ERP sustava bavili su se i Vuković, Džambas, Blažević [93] koji kažu : „ERP kao skup upravljačkih alata kojima se usklađuju potražnja i dobava, a imaju sposobnost da povezuju kupce i dobavljače u potpuni dobavni lanac, pri tome koristeći dokazane i provjerene upravljačke i planerske alate, čime se postižu visoki stupnjevi integracije među funkcijama kao što su: prodaja, marketing, proizvodnja, operacije, logistika, nabava, financije, razvoj novog proizvoda i upravljanje ljudskim resursima, te se time omogućava ljudima, zaposlenicima odnosno djelatnicima obavljanje poslova uz visoke stupnjeve usluge i produktivnosti, istodobno smanjujući troškove i zalihe, čime ERP postavlja temelje efikasnom e-poslovanju. Koncept ERP-a može se promatrati iz različitih perspektiva. ERP je proizvod u obliku računalnog softvera, ili, ERP je sredstvo dokumentiranja i redovitog ažuriranja svih informacija i podataka te procesa u organizaciji, čime on stvara smislenu integralnu strukturu. Klaus, Rosemann i Gable, definiraju ERP kao smisljeno i kompaktno softversko rješenje koje teži integriranju svih procesa u poslovnom sustavu u cilju prezentiranja cjelovitog pogleda na organizaciju putem jedinstvene informacijske i IT arhitekture, dok Yen, Chou i Chang, ERP opisuju kao softver koji se koristi za integraciju informacija kroz sve funkcionalne cjeline organizacije da bi se automatizirali poslovni procesi. ERP Systems ili Enterprise Systems su softverski paketi namijenjeni upravljanju i vođenju poslovnih sustava, a sastavljeni su od modula i aplikacija koje podržavaju funkcionalna područja kao što su: planiranje, proizvodnja, marketing, distribucija, računovodstvo, financije, upravljanje ljudskim resursima, vođenje projekata, upravljanje zalihama, održavanje, transport, e-poslovanje itd. Potrebno je naglasiti da ERP nije softver, softverski paket ili skup računalnih aplikacija. Softverski paketi ERP-sustavi ili ES samo pružaju podršku efikasnom i učinkovitom planiranju resursa odnosno ERP-u. Osnovna funkcija ERP-a je da integrira operacijske procedure unutar odjela s informacijskim upravljačkim sustavom, te da relocira organizacijske resurse u promjenjivom okruženju. ERP-sustavi su integrirana softverska rješenja koja se koriste pri upravljanju resursima određene organizacije. Zapravo, ERP-sustavi ne samo da se koriste u planiranju resursa, nego integriraju sve

odjele i funkcije organizacije u jedinstven računalni sustav koji koriste svi odjeli za rješavanje svojih zadataka.“

Prema Gartneru [33], ERP sustavi imaju sljedeća svojstva: namijenjeni su potpori aktivnostima u širokom području primjene, omogućavaju integraciju u smislu dijeljenja pristupa podacima među različitim organizacijskim jedinicama poduzeća, modularne su arhitekture, namijenjeni su određenoj industriji te obuhvaćaju standardizirane postupke rada izrađene prema najboljoj praksi za ključne procese. Nadalje, Gartner smatra da ERP pruža integraciju poslovnih funkcija kao što su financije, nabava i prodaja u skup povezanih modula čime se unapređuju poslovni procesi i korištenje informacija u organizaciji. U domaćoj stručnoj literaturi [2] navodi se kako „Gartner definira ERP kao aplikacijsku strategiju usmjerenu na nekoliko različitih tržišta paketa poslovnih aplikacijskih rješenja. ERP se uobičajeno smatra skupom tzv. uredskih (back-office) aplikacija, no ERP aplikacije uobičajeno automatiziraju i podržavaju više od samih administrativnih procesa te uključuju podršku proizvodnji i upravljanju zalihama, kao i upravljanju sredstvima unutar samog poduzeća. Gartner je, stoga, ERP podijelio u četiri glavna područja pružanja podrške poslovnim procesima: upravljanje sredstvima poduzeća (EAM-Enterprise Asset Management), sustav upravljanja financijama (FMS-Financial Management Systems), upravljanje ljudskim potencijalom (HCM-Human Capital Management) te upravljanje proizvodnjom i proizvodnim operacijama (Manufacturing and Operations).“

Prema organizaciji International Data Corporation (IDC, [38]), ERP rješenje (ili Enterprise Application Suite) je „splet integriranih poslovnih aplikacija koji zadovoljava sljedeće kriterije:

1. **Minimalna funkcionalnost** – sadrži najmanje četiri temeljne funkcionalnosti:
 - financijske aplikacije (računovodstvene module)
 - module za upravljanje nabavom
 - module za upravljanje narudžbama
 - module za upravljanje inventarom tvrtke.
2. **Integriranost** – projektirana na osnovi jedinstvenih pravila i metadata, omogućava korisnicima pristup svim funkcionalnim modulima putem jednog sučelja, može spremiti ili povući podatke iz jedne zajedničke baze podataka.

3. **Relativno visoka cijena po korisniku** - tako da se odvaja od low-end, najčešće knjigovodstvenog softvera.
4. **Višekorisnička platforma** – aplikacija je projektirana za server/host i client/server okruženja.“

Domaća stručna javnost bavila se temom ERP sustava u posebnom izdanju časopisa VIDI [91], a prema kojem je ERP „zaokružen paket poslovnih aplikacija kojem je cilj integrirati sve poslovne procese i odjele u kompaniji u jedinstveni, transparentni poslovni kompjutorski sustav sa jedinstvenom bazom podataka. Ukoliko je ERP kvalitetno sproveden on omogućuje funkcionalno dijeljenje informacija unutar kompanije i izvan kompanije s ciljem veće produktivnosti rada, uštede vremena i konačno – većeg profita.“

5.2. Klasifikacija ERP sustava

Kao što nema jedne opće prihvaćene definicije pojma ERP sustav, tako ne postoji jedinstveno prihvaćena klasifikacija ERP sustava. Postoji nekoliko kriterija prema kojima možemo klasificirati ERP sustave:

- 1) prema djelatnosti organizacije (takozvanoj industriji),
- 2) prema skupu djelatnosti organizacija u jednoj industrijskoj grani (takozvanoj vertikalnoj industriji),
- 3) prema poslovnom području kojima su programski proizvodi namijenjeni (npr. računovodstvo ili financije, upravljanje kadrovima, prodaja, nabava, isl.),
- 4) prema načinu implementacije,
- 5) prema pristupu prilagodbe ERP sustava potrebama organizacije.

Za klasifikaciju ERP sustava prema djelatnosti ili vertikalnoj industriji je nužno odabrati popis djelatnosti prema kojem će se ERP sustav klasificirati. Jakupović, Pavlić i Fertalj, predlažu klasifikaciju 70 poslovnih operacija svrstanih u tri osnovne klase operacija (financije i javne službe, proizvodnja i usluge) koje su nastale analizom klasifikacija komercijalnih proizvođača ERP sustava, klasifikacijom prema standardu Global Industry Classification Standard (GICS) i EUROSTATovom klasifikacijom. Dvije od djelatnosti (ili „industrija“) su visoko obrazovanje i istraživanje koje su predmet ovog rada [40].

Klasifikaciju su autori izradili kako bi klasificirali proizvođače ERP sustava prema kriteriju pokrivenosti poslovnih operacija gotovim modulima ERP sustava odabranih proizvođača. U izvornom obliku je klasifikacija poslovnih operacija prikazana u tablici 5.1. Autori koriste definiciju ERP sustava organizacije IDC.

Tablica 5.1.: Klasifikacija poslovnih operacija za potrebe klasifikacije ERP sustava [40]

Financial and Public Services	Manufacturing	Service
1. Banking 2. Capital Markets 3. Insurance Defense & Security 4. Defense Logistics 5. Public Security Healthcare 6. Healthcare Payers 7. Healthcare Providers Education & Research 8. Schools 9. Higher Education 10. Research Public Sector 11. Government 12. Public Security	Aerospace & Defense 13. Aerospace and Defense Manufacturers 14. Airline Management 15. MRO/M&E Service Providers Automotive 16. Automotive OEMs 17. Sales and Service Organizations 18. Automotive Suppliers 19. Chemicals 20. Shipbuilding 21. Agricultural Consumer Products 22. Apparel and Footwear 23. Beverage 24. Consumer Durables and Home Appliances 25. Food 26. Home and Personal Care 27. Engineering, Construction & Operations High Tech 28. Business, Medical, and Consumer OEMs 29. Electronics Manufacturing Service Providers 30. Semiconductor and Component Manufacturers 31. Software Providers 32. Industrial Machinery & Components Life Sciences 33. Pharmaceuticals 34. Biotechnology/Biopharmaceuticals 35. Medical Device/Scientific Instruments Mill Products 36. Building Materials 37. Fabricated Metal Products 38. Furniture 39. Packaging 40. Plastics 41. Primary Metals 42. Pulp and Paper 43. Textile 44. Rubber 45. Timberlands and Solid Wood 46. Mining 47. Oil & Gas	48. Logistics Services Media 49. Broadcasting 50. Entertainment 51. Newspapers and Magazines 52. Premium Content Publishers 53. Postal Services 54. Professional Services 55. Railways 56. Marine Transportation 57. Retail 58. Facilities Management 59. Not for Profit & Charities 60. Rental 61. Hospitality 62. Real Estate 63. Telecommunications Utilities 64. Generation 65. Retail 66. Transmission and Distribution 67. Gas 68. Waste 69. Water 70. Wholesale Distribution

ERP sustavi za svaku od navedenih djelatnosti iz tablice 5.1. se standardno koriste i implementiraju pojedinačno za svaku organizaciju. Povezivanjem organizacija u takozvanu vertikalnu industriju očekuje se i povezivanje njihovih informacijskih sustava. Vertikalnu industriju u slučaju visokog obrazovanja u RH čini nekoliko institucija koje zajednički djeluju u širem području visokog obrazovanja. To su visoka učilišta koja izvide nastavnu i znanstveno-istraživačku djelatnost, Sveučilišta (za visoka učilišta koja djeluju u sklopu Sveučilišta), Studentski centar koji se bavi studentskim aktivnostima i studentskim standardom, nadležno Ministarstvo znanosti, obrazovanja i športa, te Ministarstvo financija posredstvom kojeg se obavljaju plaćanja iz Državne riznice. Način povezivanja informacijskih sustava za vertikalnu industriju visokog obrazovanja će se razmotriti u poglavlju 7.

Prema načinu implementacije, odnosno s obzirom na opseg funkcionalnosti moduli ERP sustava se mogu implementirati na tri načina:

- u paketu - kao cjelovito rješenje koje obuhvaća sve raspoložive module;
- grupno – kao skup dva ili više modula namijenjenih potpori određenom skupu poslova, na primjer poslovima prodaje i računovodstva;
- ili pojedinačno – odnosno za potporu samo nekim odabranim procesima ili poslovnim područjima (npr. samo za financije ili samo za nabavu).

Prema stupnju prilagodbe ERP sustava potrebama organizacije Parr i Shanks [71] predlažu tri pristupa prilagodbe (*ili engl. Customization*): opsežna prilagodba (*engl. Full/comprehensive*), „zlatna sredina“ (*engl. Middle-road*) i površna (*ili engl. „Vanilla“*) prilagodba.

Opis pristupa je prikazan u sljedećoj tablici (tablica 5.2.).

Tablica 5.2.: Taksonomija pristupa ERP implementacije

Kategorija	Fizički opseg		Opseg BPR-a		Tehnički opseg		Strategija implementacije ERP-a		Opseg resursa – vrijeme i proračun ca.
Opsežna prilagodba	Jedinstvena lokacija Lokacijska distribuiranost Internacionalne lokacije	X X	Prilagodba ERP-u Lokalni BPR Internacionalni BPR	X X	Nema prilagodbe modula ERP-a Minimalna prilagodba modula ERP-a Značajna prilagodba modula ERP-a	X X	Mogućnost 1: Osnovni skup modula Puna funkcionalnost +/- industrijski specifični moduli Mogućnost 2: Modul po modul Integracija ERP-a i postojećeg IS-a	X X X X	Vrijeme ca. 4 godine Proračun ca. \$10 milijuna
Zlatna sredina	Jedinstvena lokacija Lokacijska distribuiranost Internacionalne lokacije	X X	Prilagodba ERP-u Lokalni BPR Internacionalni BPR	X X	Nema prilagodbe modula ERP-a Minimalna prilagodba modula ERP-a Značajna prilagodba modula ERP-a	X X	Mogućnost 1: Osnovni skup modula Puna funkcionalnost +/- industrijski specifični moduli Mogućnost 2: Modul po modul Integracija ERP-a i postojećeg IS-a	X X X	Vrijeme ca. 12 mjeseci Proračun ca. \$3 milijuna
Površna prilagodba	Jedinstvena lokacija Lokacijska distribuiranost Internacionalne lokacije	X	Prilagodba ERP-u Lokalni BPR Internacionalni BPR	X	Nema prilagodbe modula ERP-a Minimalna prilagodba modula ERP-a Značajna prilagodba modula ERP-a	X	Mogućnost 1: Osnovni skup modula Puna funkcionalnost +/- industrijski specifični moduli Mogućnost 2: Modul po modul Integracija ERP-a i postojećeg IS-a	X X X	Vrijeme ca. 6-12 mjeseci Proračun ca. \$1-2 milijuna

Pristup ERP implementaciji prema Shanks i Parr, treba odabrati prema potrebama i mogućnostima organizacije:

1. „Opsežna prilagodba“ (engl. Comprehensive) - zahtijeva opsežnu prilagodbu gotovih modula ERP alata s obzirom na procese, geografsku distribuiranost, integraciju poslova, integraciju rezultata obrade informacija, a sve s ciljem dobivanja informacijskog sustava prilagođenog potrebama organizacije. Ovaj pristup zahtijeva najveću investiciju i alokaciju resursa organizacije, ali i donosi najbolje rezultate.
2. „Zlatna sredina“ (engl. Middle Road) – pristup odabira zlatne sredine je upravo to što i samo ime kaže – niti opsežna prilagodba niti „Vanilla-ERP“. Sukladno ovom pristupu mogu se odabrati područja nad kojima će biti proveden reinženjering, koji nije značajan u odnosu na prvi pristup i područja. Isto tako je karakteristično za ovaj pristup da ERP-om neće biti obuhvaćeno cjelokupno poslovanje organizacije.

3. „Površna prilagodba“ (engl. Vanilla ERP) - ovaj pristup je dobar kada organizacije nisu zadovoljne vlastitim postojećim procesima a uvođenjem gotovog IS-a očekuju implementaciju „modela najbolje prakse“. To su organizacije koje su odlučile da ne žele ulagati niti u reinženjering procesa prema vlastitom viđenju i zahtjevima niti u značajnu prilagodbu gotovog IS-a novim procesima, već žele uvesti procese na temelju kojih je IS nastao i koje taj sustav u potpunosti podržava. Stupanj prilagodbe (engl. Customisation) je najniži mogući te ne zahtijeva dodatne investicije kod uvođenja.

Opseg i pristupe prilagodbi aplikacija ERP sustava valja detaljnije istražiti. Naime, kod uvođenja ERP sustava se svaki od pristupa prilagodbi aplikacija može odabrati s obzirom na razinu unapređenja procesa koje aplikacije trebaju podržavati. Doprinos o toj temi je kao rezultat rada na ovoj disertaciji autorica je objavila u znanstvenom članku u časopisu Journal of Information and Organizational Sciences 2010. godine.

5.3. Metodike uvođenja ERP sustava

Način implementacije ovisi o potrebama i mogućnostima organizacije. Ako se ERP sustav ne implementira paketno u cjelini, već grupno ili pojedinačno, onda treba odabrati procese ili grupe poslova koji će biti podržani ERP sustavom. Svaki proizvođač ERP sustava preporučuje metodiku implementacije namijenjene određivanju funkcijskih područja i modula za potporu poslovanju. U nastavku ću se osvrnuti na četiri metodike implementacije ERP sustava:

- a) Dynamics Sure Step metodika (organizacije Microsoft),
- b) Accelerated SAP (organizacije SAP AG),
- c) SPIS metodika i
- d) generički model životnog ciklusa razvoja ERP sustava.

Dynamics Sure Step metodika nije vezana isključivo uz ERP alat Navision, već se može koristiti za proizvode grupe MS Dynamics (npr. CRM, RMS). Metodika obuhvaća 6 faza: Dijagnostika (*engl. Diagnostic*), Analiza (*engl. Analysis*), Dizajn (*engl. Design*), Razvoj (*engl. Development*), Uvođenje (*engl. Deployment*) te Operativno korištenje (*engl.*

Operations). U poslijeprodajnim aktivnostima predviđa se i optimizacija i nadogradnja sustava, što međutim nije dio uvođenja alata. U tablici 5.3. su navedeni koraci po fazama te ključni dokumenti čiji su nazivi navedeni na engleskom jeziku zbog standardiziranih naziva i izvornosti.

Tablica 5.3.: Koraci metodike Dynamics Sure Step¹⁶

Faze metodike	Koraci metodike	Ključni dokumenti ¹⁷
Dijagnostika	<ul style="list-style-type: none"> • Priprema dijagnostike • Analiza na najvišoj razini ili detaljna analiza poslovnog sustava • Određivanje granica sustava • Analiza infrastrukture • Usklađivanje prijedloga i dokumenata 	<ul style="list-style-type: none"> • Business Process Worksheet • Infrastructure Assessment • Statement of Work • Proposal
Analiza	<ul style="list-style-type: none"> • Planiranje • Planiranje obrazovanja • Detaljna analiza poslovnih procesa • Planiranje prijenosa podataka (izvodi se paralelno sa planiranjem obrazovanja i detaljnom analizom poslovnih procesa) • Analiza dokumenata i postojećih zahtjeva • Usklađivanje prijedloga i dokumenata 	<ul style="list-style-type: none"> • Project and Training Plan • Business Process Worksheet • Data Migration Plan • Functional Requirements Document
Dizajn	<ul style="list-style-type: none"> • Planiranje • Izrada specifikacija za dizajn • Dizajn prijenosa podataka (izvodi se paralelno sa izradom specifikacija za dizajn) • Izrada specifikacija za tehnički dizajn • Usklađivanje prijedloga i dokumenata 	<ul style="list-style-type: none"> • Design Specifications • Technical Design Specifications • Data Migration Design • Test Plan, Test Classes
Razvoj	<ul style="list-style-type: none"> • Planiranje • Definiranje granica postavki programskog okruženja • Razvoj • Testiranje od strane korisnika 	<ul style="list-style-type: none"> • Data Migration functionality coded and tested • Features/modifications coded and tested • Test Results • Technical and End User Documentation
Uvođenje	<ul style="list-style-type: none"> • Ubrzano uvođenje (ako se počinje iz faze dijagnostike) • Planiranje (ako se počinje iz faze razvoja) • Konfiguracija postavki programskog okruženja • Testiranje • Pokretanje 	<ul style="list-style-type: none"> • Go-Live Plan /Checklist • Test Plan • System Configuration
Operativno korištenje	<ul style="list-style-type: none"> • Priprema zatvaranja projekta • Potpora nakon pokretanja • Zatvaranje projekta • Revizija projekta • Potpora u korištenju sustava • Upravljanje i administracija korištenja i daljnjeg licenciranja 	<ul style="list-style-type: none"> • Technical Documentation • End User Documentation • Functioning Live System

¹⁶ Izvor: Microsoft [58]

¹⁷ nazivi na engleskom jeziku zbog standardiziranih naziva unutar MS

Druga metodika je Accelerated SAP (ili kraće ASAP) proizvođača ERP alata SAP. Metodika obuhvaća 5 koraka: Pripremu projekta (*engl. Project Preparation*), Izradu modela poslovanja (*engl. Business Blueprint*), Razvoj (*engl. Realization*), Završnu pripremu (*engl. Final Preparation*) i Upogonjenje i podršku (*engl. Go-Live & Support*). U tablici 5.4. su navedeni koraci po fazama te ključni dokumenti čiji su nazivi navedeni na engleskom jeziku zbog standardizacije i izvornosti.

Tablica 5.4.: Koraci metodike ASAP¹⁸

Faze metodike	Koraci metodike	Ključni dokumenti ¹⁹
Priprema projekta	<ul style="list-style-type: none"> • Inicijalno planiranje projekta • Definiranje ciljeva projekta • Definiranje uloga i ključnih područja • Određivanje strategije implementacije • Analiza i potvrđivanje plana implementacije • Izrada prijedloga proračuna projekta • Uspostavljanje projektnog tima • Definiranje obveza i odgovornosti članova tima • Kreiranje plana obuke za članove projekta • Definiranje tehničkih zahtjeva • Planiranje aktivnosti projekta 	<ul style="list-style-type: none"> • Project Goals and Objectives • Project Charter • Project Plan • Scope • Project Team Organization • Standards and Procedures • Plan /Budget / Resources • Implementation Strategy • Change Management Plan • ID Tech Requirements / Hardware Procurement
Izrada modela poslovanja	<ul style="list-style-type: none"> • Razvoj i donošenje plana obuke za članove tima • Planiranje tehničkog razvoja • Procjena procesa, kompetencija i potencijalnih točki unapređenja • Definiranje poslovnih procesa • Izrada modela • Razvoj poslovnih scenarija slučaja • Izrada modela rješenja • Upravljanje promjenama u organizaciji • Obuka za fazu izrade modela poslovanja • Planiranje aktivnosti tehničkog razvoja • Uspostava okoline za razvoj sustava • Definiranje organizacijske strukture • Definiranje poslovnih procesa 	<ul style="list-style-type: none"> • Training Plans • Technical Design Plan • Process Requirements • Business Blueprint (Business Area Strategy Model, Business Area Operations Model, Business Area Information Model, Business Area Requirements Report, Business Area Requirements Dana Gathering Materials) • Solution Model • Master Data • Cross Application development
Razvoj	<ul style="list-style-type: none"> • Vođenje projekta • Upravljanje promjenama u organizaciji • Obuka za fazu razvoja • Uspostavljanje okoline za produkciju • Razvoj planova za testiranje sustava • Uspostavljanje okoline za upravljanje kvalitetom • Razvoj osnovne konfiguracije • Testiranje • Razvoj završne konfiguracije • Autorizacija • Integracija • Uspostavljanje tijekova rada, programiranje, konverzije, prototipiranje i uspostava sučelja 	<ul style="list-style-type: none"> • Business Process Master List • Test Scenarios • Training Material • Program Development • Configuration Plan • Testing Plan

¹⁸ Izvor: SAP, [86]

¹⁹ nazivi na engleskom jeziku zbog standardiziranih naziva unutar SAP

Završna priprema	<ul style="list-style-type: none"> • Obuka korisnika • Upravljanje sustavom • Izrada korisničke dokumentacije • Prijenos podataka • Završna integracija i testiranje sustava • Testiranje kvalitete završne pripreme 	<ul style="list-style-type: none"> • Cutover Plan • Volume Test • Stress test • Technical Operations Manual • Technical an End User Documentation
Upogonjenje i podrška	<ul style="list-style-type: none"> • Pokretanje sustava • Pružanje podrške korisnicima 	<ul style="list-style-type: none"> • Go-Live Check List • Production Support Plan • System Performance Review

Treća metodika je SPIS metodika koja obuhvaća skup međusobno povezanih metoda i tehnika čijom se konzistentnom primjenom modeliraju poslovni i informacijski sustav neke organizacije. Metodika SPIS ne propisuje uvođenje gotovog ERP alata za potporu poslovanju, već preporučuje da treba odabrati odgovarajući alat prema potrebama poslovnog sustava (tablica 5.5.).

Tablica 5.5.: Kratki pregled metodike SPIS – koraci i metode [92]

Problem/korak razvoja IS	Metode i tehnike (§ -strateške, # -strukturirane, □ -objektno orijentirane)	Ulazne i izlazne vrijednosti <i>Input / Output</i>	Korisnost Vrlo utjecajno Utjecajno, Korisno
1. Opis poslovnog sustava (PS)	Intervju	<i>Misija i ciljevi postojećeg PS / Strategija organizacije; Poslovni procesi (PP)</i>	
2. Procjena utjecaja novih IT na poslovni sustav	§ Balanced Scorecard § BCG-matrica § 5F-model § Value-chain model (Porter)	PP / Performanse postojećeg PS Strategija organizacije / prioriteti razvoja IS <i>Strategija organizacije / Informiranje top-menadžmenta</i> <i>PP / Početni (temeljni i potporni) poslovni procesi (PPP)</i>	V U K V
3. Redefiniranje poslovnih procesa	# dekompozicija poslovnih procesa # analiza životnog ciklusa resursa	PPP / Nove organizacijske jedinice (OJ) <i>Osnovni resursi / Mapa poslovnih procesa</i>	U U
4. Preustroj poslovnog sustava	§ BPR reinženjering poslovnih procesa § SWOT analiza	Mapa poslovnih procesa / Novi poslovni procesi (NPP) <i>Mapa poslovnih procesa / SWOT analiza NPP</i>	U V
5. Određivanje kritičnih informacija	§ CFS analiza (Rockart) # Ends-Means analiza	<i>NPP / Kritične informacije za NPP</i> <i>NPP / Informacije o djelotvornosti i učinkovitosti poboljšanja</i>	U K
6. Optimalizacija arhitekture novog IS	# Matrica procesi-klase podataka # Afinitetna analiza, genetički algoritmi	<i>NPP / Povezanost poslovnih procesa</i> <i>Povezanost poslovnih procesa / Grupiranje; Podsustavi novog IS</i>	V U
7. Modeliranje nove poslovne tehnologije (PT)	# Dijagram tokova rada (WFD) # Dijagram organizacijskih tokova	NPP / Odgovornost za NPP Nove OJ / Tokovi između novih OJ <i>NPP / Aktivnosti NPP</i>	V U K

	(OFD) # Dijagram tokova aktivnosti (AFD)		
8. Modeliranje novih poslovnih procesa koji će biti podržani IT	# Dijagram toka podataka (DFD) # Akcijski dijagram (AD)	<i>NPP</i> / Podrška <i>NPP</i> suvremenim IT (Procesi IS); Podatkovni tokovi; Podaci PS <i>Procesi IS</i> / Unutarnja logika procesa IS	V U
9. Procjena učinkovitosti novog IS	# Simulacijsko modeliranje	<i>Procesi IS</i> / Smjernice za poboljšanja PP	K
10. Modeliranje novih poslovnih podataka	# ERA-model ▫ Objekt-model	<i>Podaci PS</i> / ERA model <i>Podaci PS</i> / Objekt-model	V U
11. Dizajn softvera	# HIPO- dijagram ▫ Dijagram tranzicije	<i>Procesi IS</i> / Logičko modeliranje aplikacija (SW) <i>Tokovi podataka</i> / Događaji i transakcije	V U
12. Detaljan dizajn programa i procedura	# Akcijski dijagram ▫ Scenarij objekta	<i>Logičko modeliranje programa i programskih procedura (SW)</i> / Model programske logike <i>Objekt-model</i> ; <i>Događaji</i> / Ponašanje objekata	U U
13. Razvoj modela podataka	# Relacijski model; Normalizacija	<i>ERA model</i> / Relacijski model	V
14. Razvoj softvera	# CASE alati i programski jezici 4. generacije ▫ OO-CASE alati	<i>Model programske logike</i> ; <i>Relacijski model</i> / Programi i procedure <i>Ponašanje objekata</i> / OO-procedure	U U
15. Implementacija novog IS	# Case-study; Poslovne igre	<i>Programi i procedure</i> / Performanse novog IS	U
16. Procjena performansi novog poslovnog sustava	# Balanced scorecard	<i>Performanse postojećeg PS</i> ; <i>Performanse novog IS</i> / Mjerenje uspjeha	V

Četvrta metodika je generički model životnog ciklusa razvoja ERP sustava (tablica 5.6.) a prezentirana je u znanstvenom radu Ahituv et.al. [1]. Prednost koju nosi ova metodika, a koju autori žele naglasiti jest da se ona temelji na tradicionalnom pristupu razvoja IS-a prema životnom ciklusu, na prototipnom pristupu i pristupu prema životnom ciklusu razvoja aplikacija.

Tablica 5.6.: Faze i koraci generičkog modela razvoja ERP-a [1]

Faza	Koraci
1. Selekcija	<ol style="list-style-type: none"> 1) Definicija ciljeva projekta 2) Prikupljanje informacija o postojećim ERP proizvodima i proizvođačima 3) Prikupljanje informacija o konzultantima za uvođenje ERP sustava 4) Analiza potreba organizacije 5) Odabir potencijalnih proizvođača koji zadovoljavaju potrebe organizacije 6) Odabir potencijalnih konzultanata 7) Analiza tehnološke infrastrukture organizacije prema zahtjevima odabranih ERP sustava 8) Izrada studije izvodljivosti 9) Pregovaranje i potpisivanje ugovora
2. Definicija	<ol style="list-style-type: none"> 1) Određivanje opsega projekta 2) Imenovanje članova projektnog tima i utvrđivanje rokova 3) Obuka članova projektnog tima 4) Pokretanje odabranih funkcionalnosti u testnom okruženju
3. Implementacija (koraci 1-3 se provode iterativno)	<ol style="list-style-type: none"> 1) Dodavanje nove funkcionalnosti (za odabrani poslovni proces) 2) Konverzija podataka 3) Uspostavljanje radnih procedura 4) Pokretanje funkcionalnosti u stvarnom okruženju 5) Obuka korisnika 6) Testiranje sukladnosti
4. Operacionalizacija	<ol style="list-style-type: none"> 1) Uspostavljanje sustava i centara za pomoć korisnicima 2) Realizacija promjena i poboljšanja sustava 3) Nadogradnja sustava 4) Nadzor nad radom sustava 5) Ukidanje sustava (završni korak životnog ciklusa ERP-a)

U svim navedenim metodikama postoji korak ili faza koja se odnosi na identifikaciju potreba organizacije bilo kroz analizu procesa ili analizu drugih zahtjeva poslovnog sustava i mapiranje prepoznatih potreba sa funkcionalnostima budućeg informacijskog sustava koji će podržavati poslovanje. Zajednički koraci koji se mogu prepoznati u svim metodikama su: identifikacija poslovnih procesa, unapređenje poslovnih procesa, identifikacija i analiza ključnih dokumenata, identifikacija i analiza ključnih podataka, odbacivanje redundantnih informacijskih resursa (dokumenata ili podataka), obrazovanje korisnika, procjena dostupnosti računalne infrastrukture, dizajn softvera prema željama korisnika, procjena učinkovitosti alata prije implementacije, analiza i praćenje zadovoljstva korisnika novim IS-om. Ovi zajednički koraci bi se morali pronaći u preporukama najbolje prakse uvođenja ERP sustava.

5.4. Preporuke najbolje svjetske prakse uvođenja ERP sustava za visoko obrazovanje

Neil Pollock [75] smatra da su visoka učilišta podlegla unutarnjim i vanjskim pritiscima za modernizacijom tako što su se okrenula novim tehnologijama i primjeni modernih oblika upravljanja administrativnim poslovima. Navodi kako visoka učilišta nastoje postati moderne organizacije time što prestaju biti centralizirane organizacije sa jakom administracijom i transformiraju se u distribuirane sustave koji studentima omogućavaju samoupravljanje nad vlastitim podacima (*engl. Self-Service Student*). Ovakav pristup je tehnološki apsolutno provediv, međutim pitanje je koji podaci mogu biti dostupni studentima za samoupravljanje i time smanjiti operativne troškove administracije na visokim učilištima.

Frantz, Southerland i Johnson proveli su istraživanje percepcije stručnog osoblja (CIO i CFO) na visokoobrazovanim institucijama o najboljoj praksi uvođenja ERP sustava [32]. U istraživanju je analizirano 159 valjanih odgovora (što predstavlja postotak odaziva od 53%). Od 24 ponuđenih izjava, CIO i CFO su se složili oko 7 najvažnijih preporuka, koje su prema Likertovoj skali ocijenjene ocjenom 4,6 ili više:

1. Uprava organizacije mora podržavati i biti sponzor projekta implementacije ERP sustava.
2. Odgovornost za implementaciju ERP sustava trebaju dijeliti odjel za primjenu informacijskih tehnologija i predstavnici poslovnih funkcija u čije se odjele uvodi ERP sustav.
3. Uprava mora procijeniti spremnost institucije na prihvaćanje organizacijskih promjena uvjetovanih implementacijom ERP sustava.
4. Voditelj projekta implementacije treba biti zaposlen s punim radnim vremenom na poslovima implementacije.
5. Projektni tim treba okupljati stručnjake iz svih poslovnih područja uključenih u projekt uvođenja ERP-a.
6. Vlasnik procesa implementacije ERP-a mora biti institucija u koju se ERP uvodi.
7. Svi zaposlenici koji će koristiti ERP sustav moraju proći temeljitu obuku za osposobljavanje za rad s novim sustavom.

Prema rezultatima istraživanja Bologna et. al. [6], ključni faktori za uspjeh uvođenja ERP sustava su: komunikacijska struktura koja podrazumijeva jasne procedure i dobro strukturirane kanale komunikacije, uključenost upravljačkih tijela, organizacijske karakteristike kao što je organizacijska kultura ili spremnost na promjene, te kompetentnost tima odgovornog za uvođenje ERP-a. Važnost ova četiri faktora potvrđuje i Rabaa'i [78] te dodaje kako su uz to važni i kvaliteta upravljanja projektom uvođenja ERP-a i kvaliteta tehnološkog partnera koji uvodi/razvija ERP.

Svakako treba spomenuti i zbirke modela najbolje prakse koji su uglavnom opisani tekstualno, dostupne na stranicama organizacija:

- The Southern Association of College and University Business [88];
- Florida Atlantic University [35].

6. Podaci i moduli ERP sustava za visoka učilišta

Primjenom metoda za modeliranje poslovnih procesa su izrađeni modeli procesa i njihovih aktivnosti u poglavlju 3. Ti modeli detaljno prikazuju podatkovne i druge poslovne sadržaje koje procesi i aktivnosti međusobno razmjenjuju. Podatkovni sadržaji na modelima su polazišna osnova za definiranje podatkovne infrastrukture budućeg informacijskog sustava za upravljanje resursima visokih učilišta. U ovom poglavlju će se na temelju modela procesa izraditi matrica poslovne tehnologije koja obuhvaća procese i klase podataka. Pod klasom podataka ćemo smatrati svaki skup podataka koji je od interesa u određenoj namjeni definiranoj procesom koji ju koristi ili kreira. Grupiranjem namjenski srodnih procesa i njihovih klasa podataka definirati ćemo informacijske podsustave budućeg ERP sustava. Za definirane klase će se u nastavku poglavlja izraditi podatkovni model, a za formirane informacijske podsustave mapirati moduli postojećih komercijalnih ERP sustava visokih učilišta.

6.1. Matrica poslovne tehnologije

Matrica poslovne tehnologije služi za analizu veza procesa i klasa podataka. Proces i mogu stvarati, čitati, ažurirati i brisati podatke. U matrici se za svaku vezu stvaranja, čitanja, ažuriranja i brisanja u odgovarajuću ćeliju zapisuje odgovarajuća oznaka veze C, R, U ili D prema engleskim nazivima za veze (create, read, update, delete). Nad matricom u koju su zapisane sve veze, moguće je provesti analizu srodnosti procesa po kriteriju sličnosti korištenja ili srodnosti klasa po kriteriju postojanja veze prema procesima. Analiza srodnosti procesa može poslužiti za grupiranje procesa, a grupiranjem procesa i njihovih klasa možemo odrediti podsustave budućeg informacijskog sustava.

U tablici 6.1. je prikazana matrica veza procesa i klasa podataka izrađena prema modelima procesa iz poglavlja 3. Analiza srodnosti procesa se provodi pomoću empirijskog grupiranja procesa prema redoslijedu faza životnog ciklusa osnovnih resursa koje procesi koriste, pomoću afinitetne analize za grupiranje procesa prema matematičkom izračunu srodnosti procesa i pomoću drugih grupirajućih algoritama (npr. genetički algoritmi). Grupiranje procesa visokih učilišta je provedeno s obzirom na redoslijed procesa u fazama životnog ciklusa osnovnih resursa iz poglavlja 2 i afinitetne analize.

Tablica 6.1. Matrica veza procesa i klasa podataka visokih učilišta

[illegible]

Dobivene grupe čine podsustave budućeg informacijskog sustava, jer su procesima i klasama podataka određene funkcionalnosti aplikacija budućeg IS-a i pripadne baze podataka nad kojom će se izvršavati aplikacije. Složeni podsustav namijenjen potpori nastavnoj djelatnosti je razrađen detaljnije, time što su za taj podsustav naznačene jednostavnije funkcionalne cjeline. Struktura informacijskog sustava visokih učilišta izvedena iz matrice procesa i klasa podataka je sljedeća:

- Informacijski sustav visokog učilišta:
 - Informacijski podsustav za nastavnu djelatnost
 - Upravljanje NPP
 - Upisi na studij i u obrazovne cikluse
 - Izvođenje nastave i rad sa studentima
 - Promocija i izdavanje javnih isprava
 - Izvannastavne aktivnosti
 - Organizacija nastave
 - Informacijski podsustav za upravljanje akademskim razvojem
 - Informacijski podsustav za znanstveno istraživačku djelatnost
 - Informacijski podsustav za stručno komercijalnu djelatnost
 - Informacijski podsustav za potporne djelatnosti
 - Informacijski podsustav za upravljanje visokim učilištem.

Procesi informacijskih podsustava trebaju biti podržani modulima ERP sustava. Moduli mogu biti sastavljeni od jedne ili više aplikacija. Konačan broj i struktura modula se utvrđuje tijekom izgradnje informacijskog sustava u realnoj organizaciji. Struktura modula ne mora nužno korespondirati sa predloženom strukturom, ali funkcionalno mora biti prilagođena predloženim podsustavima.

6.2. Model podataka ERP sustav za visoka učilišta

U matrici poslovne tehnologije analizirane su veze procesa i klasa podataka koje procesi koriste. Klase podataka se u informacijskom sustavu realiziraju kao elementi baze podataka nad kojom će raditi aplikacije razvijene prema funkcionalnostima koje proizlaze iz procesa koje aplikacije trebaju podržavati.

Matrica procesa i klasa podatka je istovremeno stoga i polazišna osnova za izradu modela podataka. Podatkovni model prikazuje organizaciju podataka o resursima i transakcijama visokih učilišta kroz objekte i odnose između objekata prikazane vezama. Objekti su klase istovrsnih pojava (ljudi, organizacija, usluga i sl.) i sadrže najvažnije attribute, koji predstavljaju tipove podataka koji će se zapisivati u bazi podataka visokog učilišta. Kada se u bazi podataka kreira slog koji opisuje instancu objekta iz realnog svijeta, onda dobivamo **matične podatke** ili zapise o stvarnim ljudima, organizacijama, uslugama. Za neke od atributa potrebno je definirati skupove mogućih stanja koji su bitni za klasificiranje te jednoznačno praćenje i vođenje statistike o instancama objekata iz realnog svijeta. Takvi skupovi mogućih stanja nazivaju se katalozi. **Katalozi** omogućavaju standardizaciju podataka na način da se stvarna pojava opisuje odabirom jednoznačne vrijednosti (oznakom) koja je dodijeljena jednom mogućem stanju i koja poprima isto značenje za sve osobe koje sudjeluju u poslovnom procesu. Objekti podatkovnog modela isto tako mogu predstavljati **podatke o poslovnim transakcijama** (npr. računi, stavke glavne knjige), ili **podatke o vezama instanci matičnih i drugih podataka**.

Korisničke aplikacije koriste objekte prikazane u logičkom modelu podataka. Objekti su prikazani pravokutnikom koji u gornjem dijelu sadrži naziv objekta, dok je ostali dio rezerviran za najvažnije attribute objekta. Veze koje prikazuju odnose između objekata u oba smjera, a brojnost (*engl. Cardinality*) i opcionalnost veze opisani su Martin-ovom notacijom. Tipovi veza s oznakama opcionalnosti i brojnosti formiraju poslovna pravila.


Model podataka visokih učilišta je prikazan na slici 6.1. Objekti koji prikazuju matične podatke su Student, Zaposlenik visokog učilišta, Predmet, Studij, Projekt, Radovi, Oblici aktivnosti, Ishodi učenja. Neki od specifičnih kataloga su Radna mjesta na visokom učilištu, Zvanja, Znanstveno područje, Kategorije radova.

Primjer specifičnog transakcijskog skupa podataka je „plan aktivnosti“ koji omogućava formiranje zapisa o planiranim aktivnostima zaposlenika na predmetima i zapisa o realizaciji planiranih aktivnosti. Primjer objekta koji opisuje vezu između dva objekta koji predstavljaju matične podatke jest objekt koji opisuje pripadnost predmeta studiju s naznakama načina pripadnosti (izborni ili obvezni predmet).

Student upisuje studij, obrazovni ciklus (npr. semestar) i predmete. Upis predmeta se obavlja uz provjeru međuvjetovanosti predmeta. Upisane predmete student može polagati na ispitnim rokovima ako postoji valjanja prijava. Uspjeh na ispitnom roku unosi jedan ili više nastavnika ovisno o modelu polaganja predmeta. Kada student prikupi dovoljan broj ECTS bodova, onda odabire temu završnog rada koju je definirao zaposlenik visokog učilišta (samo oni zaposlenici koji prema radnom mjestu na kojem su zaposleni imaju pravo definirati temu). Kada je završni rad obranjen i ocijenjen, student predaje zahtjev za izdavanjem diplome. Na temelju zahtjeva se otvara postupak i rješava zahtjev studenta prema proceduri rješavanja definiranoj aktivnostima postupka. Zaposlenici visokog učilišta rade na različitim radnim mjestima. Svi zaposlenici koji obavljaju nastavnu ili znanstveno istraživačku djelatnost, moraju planirati i evidentirati opterećenje aktivnostima u tim djelatnostima. Neke aktivnosti mogu biti vezane uz nastavu i predmete (kao što su nositeljstvo, izvođenje predavanja predmeta, izvođenje vježbi, seminara i drugih oblika nastave). Svaka aktivnost ima jediničnu satnicu i normiranu satnicu, te jedinični trošak. Na taj način se mogu planirati i pratiti troškovi aktivnosti zaposlenika. Aktivnosti vezane uz nastavu se realiziraju prema rasporedu za svaki studij. Za svaku stavku rasporeda je potrebno odabrati predmet, vrstu aktivnosti (predavanje, vježbe, seminari), zaposlenika koji izvodi nastavu, opremu, vrijeme i dvoranu (povezivanje opreme i dvorane na stavku rasporeda omogućava povezivanje indirektnih troškova s aktivnostima u nastavi). Aktivnosti vezane uz rad na projektima se prate za svaki projekt, uzimajući u obzir moguće radne aktivnosti s definiranim jediničnim troškom i satnicom. Rezultati znanstveno istraživačkog rada se prezentiraju u radovima koje je moguće kategorizirati te vezati uz određeno znanstveno područje. Objavljeni radovi se uzimaju u obzir kod izbora u zvanje ako su objavljeni nakon posljednjeg izbora u zvanje.

Drugi primjer specifičnog transakcijskog skupa podataka je realizacija programskog ugovora najavljenog zakonskim promjenama koje će predstavljati novi izazov za visoka učilišta u RH. Prema MZOŠ²⁰ „programski ugovor obuhvaća osnovni proračun, razvojni proračun i proračun vlastitih sredstava. Programskim ugovorom omogućuje se usklađivanje javnih politika u znanosti i visokom obrazovanju kroz dijalog sveučilišta i instituta s državnom upravom. Omogućuju se i usklađivanje financiranja s kvalitetom rada institucija, u skladu s politikom upravljanja kvalitete i provedbe institucijskih strateških programa.“ Iako nije potpuno jasno kako će se ovaj koncept financiranja provoditi, predviđeni su skupovi podataka kojima se omogućava ovakvo planiranje proračuna i financija visokog učilišta. Tako svaki „proračun“ u modelu podataka ima svoje planirane stavke s izvorom financiranja i iznosom po broju konta. Oblici aktivnosti unutar istoimenog kataloga su također vezani na konta, kao i radne aktivnosti na projektima, radi projekcije, simulacije i obračuna troškova temeljem podataka o planiranim i provedenim aktivnostima. Na taj način je omogućeno mjerenje ostvarenja ugovorenih obveza između financijera i izvođača.

²⁰ www.mzos.hr



Slika 6.1.: Prijedlog modela podataka ERP sustava visokog učilišta

Podatkovni model za visoka učilišta predstavlja strukturiran način pohrane podataka s minimiziranom redundancijom i kao takav je nezavisan od RDBM-sustava i računalne opreme s kojom će se realizirati relacijska baza podataka. Kod izvedbe baze podataka prema ovom modelu mogla bi se pokazati potreba za definiranjem dodatnih tipova objekata sa značenjem šifarnika ili kataloga. Uz nazive atributa koji poprimaju vrijednost iz kataloga je u modelu oznakom „(*)“ posebno naznačeno da će unos tog polja biti ograničen na izbor jedne od dostupnih vrijednosti iz kataloga. Takav će se slučaj pojaviti onda, kada vrijednosti nekih atributa u jakim objektima moraju biti izabrane iz točno određenog skupa dozvoljenih vrijednosti.

6.3. Moduli ERP sustava za visoka učilišta

Podsustavi koji su određeni u ovom poglavlju služe za određivanje arhitekture informacijskog sustava visokih učilišta za planiranje i upravljanje resursima visokih učilišta. Specifikacije podsustava nemaju dovoljnu razinu detaljnosti za oblikovanje i izradu budućih programskih rješenja za potporu procesima, jer ne opisuju poslovna pravila koja također utječu na funkcionalnost modula i njihovih aplikacija. Iz tog razloga se u sklopu ovog rada mogu samo načelno usporediti planirani moduli za definiranu arhitekturu sustava planiranja i upravljanja resursima visokih učilišta sa postojećim komercijalnim rješenjima.

Moduli su aplikacije ili skupovi međusobno povezanih aplikacija, formirani tako da podržavaju određenu poslovnu funkciju ili proces djelatnosti. Moduli su nastali prema predlošku organizacije ili nekog njenog procesa pri projektiranju i razvoju modula. Kod implementacije ERP sustava u bilo kojoj realnoj organizaciji, potrebno je najprije odabrati pravu kombinaciju modula prema potrebama organizacije izraženim u funkcionalnim zahtjevima (*engl. Functional Requirements*), a zatim prilagoditi module (i podatke nad kojima moduli rade) procesima organizacije (*engl. Customize*), ili obrnuto, kod projekata „uvođenja najbolje prakse“ prilagoditi procese organizacije modulima softvera, te na kraju uvesti i upogoniti sustav.

Tijekom izrade rada su analizirani postojeći ERP sustavi za visoka učilišta dostupni na tržištu. Paula King je 2002. godine za organizaciju Educause Centar for Applied Research

(skraćeno ECAR) provela istraživanje o implementaciji ERP sustava u visokim učilištima[50]. U tom istraživanju je sudjelovalo 500 institucija za visoko obrazovanje sa 481 odgovorom, a sudionici su bili članovi organizacije Educause, članovi Američkog društva javnih visokih učilišta (*engl. American Association of Community Colleges*) i članovi vijeća nezavisnih visokih učilišta (*engl. Council of Independant Colleges*). U sklopu istraživanja korištena je Gartnerovo objašnjenje pojma ERP sustava sa sljedećim svojstvima:

- ERP sustavi su namijenjeni potpori aktivnostima u širokom području primjene, uključujući upravljanje kadrovima, vođenje evidencije po studentima i potporu financijskom poslovanju;
- ERP sustavi omogućavaju integraciju u smislu dijeljenja pristupa podacima među različitim organizacijskim jedinicama poduzeća;
- ERP sustavi su modularne arhitekture;
- ERP sustavi koji su namijenjeni određenoj industriji obuhvaćaju standardizirane postupke rada izrađene prema najboljoj praksi za ključne procese.

Ciljevi uvođenja ERP sustava su prema istraživanju bili vezani uz osiguravanje podataka za učinkovito planiranje i upravljanje visokim učilištima, bolji aplikativni servisi za upravljanje podacima o zaposlenicima, studentima i visokom učilištu, smanjenju poslovnog rizika, smanjenju operativnih troškova povećanjem učinkovitosti i povećanju prihoda. Od ispitanih institucija, njih 44% nije uvelo ERP sustav, a neki od razloga su ti da su institucije zadovoljne postojećim informacijskim sustavom (32%), da trenutno imaju druge prioritete (18%) ili da nisu spremni za takav poduhvat (16%). Od 56% institucija koje su uvele ERP sustav, njih 33% je uvelo module vezane uz financije, studente i upravljanje kadrovima, njih 37% je uvelo dva od navedena tri modula, a 31% je uvelo samo jedan od navedenih modula. King navodi da je istraživanje pokazalo da nema razlike u interesu za ERP sustavima između privatnih i javnih visokih učilišta. Prilagodba ERP sustava prema potrebama visokog učilišta u 29% implementacija nije uopće provedena, u 48% slučajeva su provedene minimalne izmjene od 1 do 10% koda, u 18% uvođenja je provedena djelomična prilagodba (11-25% izmijenjenog koda), u 4% slučajeva značajna prilagodba sa 26 do 50% izmjena u kodu, dok je samo 1% implementacija obuhvaćalo ekstremne izmjene koda sa više od 50%. Razlozi za izmjene

su se odnosili na izvješćivanje, izgled/ergonomiju ekrana, odstupanja u funkcionalnostima, integraciju s drugim postojećim informacijskim sustavima i usuglašavanje ERP sustava sa poslovnim procesima.

U sljedećoj tablici je dan pregled tipova modula, proizvođača i nedavnih klijenata implementacije ERP sustava u visokim učilištima u SAD. Za europska visoka učilišta nije pronađen sličan registar. U tablici su žutom bojom označeni retci u kojima je kao tip modula navedena implementacija ERP sustava kao cjeloviti ERP sustava (*engl. Full ERP*). Tablica je dana u izvornom obliku na engleskom jeziku i nije prevedena zbog referenciranja na izvorne pojmove ERP sustava za visoka učilišta i potencijalnog gubljenja značenja tijekom prijevoda. Ovo predstavlja ozbiljan problem jer u RH nisu uvedeni odgovarajući pojmovi na hrvatskom jeziku i nema stručnog konsenzusa oko značajno velikog skupa pojmova vezanih uz ERP sustave.

Tablica 6.2.: Popis tipova modula, proizvođača i nedavnih klijenata implementacije ERP sustava u visokim učilištima u SAD²¹

Uvedeni moduli	Proizvođači ERP sustava	Klijenti
Housing, Judicial, Parking, Conference and Health Center	Adirondack Solutions	Quinnipiac University
		Barry University
Full ERP	Alliant Data Systems	East Central Community College Copiah Lincoln Community College
Facilities Scheduling	Ad Astra Information Systems	Santa Clara University
		Hartnell College
Full ERP	Agresso Americas	Bow Valley College Portage College
Full ERP	Blackbaud, Inc.	Ursinus College Providence College and Seminary
Full ERP	Campus Management Corporation	A.T. Still University Baker University
Student and Advancement	Champlain Software	
Financial Aid and Admissions	College Board PowerFacts	Carleton College
Admissions and Facilities Scheduling	CollegeNet	Western Washington University
		Pepperdine University

²¹ Higher Education Software Vendors [20]

Student and Advancement	COMSPEC Empower	Holy Cross College
		Benedictine College
Career Services	CSO	Barry University
		The Ohio State Univesity
Full ERP	Datatel	Salve Regina University
		Atlantic Cape Community College
Student and Advancement	EDC Technology	
Admissions and Financial Aid	EMAS	Delgado Community College
		Charleston Southern University
SAAS Admissions, Career Services, CRM	Enrollment Rx	Shimer College
		Hebrew Theological College
Imaging	Feith Systems and Software, Inc.	Suffolk County Community College
		Shawnee State University
Financial Aid Backoffice	Global Financial Aid Services	Greenville Technical College
		University of Mississippi
Imaging	Hershey Systems, Inc.	University of Alabama
		San Diego State University
Admissions	Hobsons Enrollment and student recruitment solutions	Boise State University
		Univ. of Central Missouri
Advancement	Hobson Strategic Vision LLC	www.hobsonstrategicvision.com
Full ERP	Jenzabar	Brigham Young University-Idaho
		Southeastern Illinois College
Open Source ERP	Kuali Foundation	Indiana University
		Cornell University
Imaging	NOLII	University of Tennessee
		Swarthmore College
Full ERP	Oracle PeopleSoft	The Ohio State University
		University of Wisconsin
HR Software	PeopleAdmin	University of Kentucky
		Bowdoin College
Imaging	Perceptive Software, Inc.	Cornell University
		Madison Area Technical College
SAAS Student System	Populi	Central Baptist Theological Seminary
		Visible School
Financial Aid	Regent Financial Aid Solutions	Washington State Tech. & Community Colleges
Full ERP	SAP America Inc.	Northern Kentucky University
Full ERP	SCAN Business Systems	Mass. School of Professional Psychology
		Newbury College
Facilities and Help Desk	SchoolDude	East Georgia College

		Penn State - Altoona
Financial Aid & Student Accounts Receivable	Sigma Systems Inc.	University of Connecticut
		University of Wisconsin - Whitewater
Student and Development	SONIS	Mesalands Community College
		Western Dakota Technical Institute
Full ERP	SunGard PowerCampus	Tompkins Cortland Community College
		Milligan College
Full ERP	SunGard SCT Banner	College of William and Mary
		Johnson County Community College
Strategic Planning & Scholarship Tracking	Think Technologies	
Full ERP	Three Rivers	Baylor College of Medicine
		Frank Phillips College
SAAS Student System	TopSchool, Inc.	American Pacific University
		Cambria-Rowe Business College
SAAS HR and Finance	workday	

Drugi pristup određivanju najjačih proizvođača je bio pomoću tehnoloških portala koji nude analizu sukladnosti ponuđenih ERP sustava komercijalnih proizvođača i potreba organizacije pomoću upitnika o organizacijskim, tehnološkim i drugim karakteristikama organizacije. Podaci o modulima ERP sustava komercijalnih proizvođača prikupljeni su sa službenih webstranica proizvođača [41, 58, 69, 85, 86]. Rezultati analize organizacije Education Strategies [20] su uzeti u obzir kod analize modula ERP sustava najzastupljenijih proizvođača ERP sustava na tržištu ERP alata za visoka učilišta (prema King [50], izvješću organizacije Enterprise Resource Planning Evaluation Center [22], Gartneru [33] i IDCu [38]). Na temelju analize modula ponuditelja ERP sustava određeni su generički nazivi modula i organizacijsko područje na koje se modul odnosi. Ti generički nazivi i referentno područje organizacije su navedeni u tablici 6.3. u desna dva stupca. U lijevom stupcu tablice 6.3. su uvršteni informacijski podsustavi dobiveni iz matrice procesa i klasa podataka.

Tablica 6.3.: Informacijski podsustavi visokih učilišta i moduli ERP sustava

Informacijski podsustavi visokih učilišta	Generički naziv modula	Organizacijsko područje
Informacijski podsustav za nastavnu djelatnost	Academic Structure and Curriculum Management, Course Management	Nastavna djelatnost
	Course Registration, Module Booking, Attendance Tracking, Class Scheduling	Nastavna djelatnost
	Registration, Degree progression Audit	Nastavna djelatnost
	e-learning portal	Nastavna djelatnost
	Faculty Portal	Nastavna djelatnost
	Grading, Assessment, Examination, Audits, Graduation	Nastavna djelatnost
	Librarian systems	Nastavna djelatnost
	Publishing portal	Nastavna djelatnost
	Research portals and systems	Nastavna djelatnost
	External Work, Equivalency Determination, Alumni	Nastavna djelatnost, alumni
	Messaging and Social Networking	Studenti
	Recruitment, Admission, Enrolment	Studenti
	Student Portal	Studenti
	Student record management	Studenti
	Contract Management	Ugovaranje
Informacijski podsustav za znanstveno istraživačku djelatnost	Research Project management	Znanstveno istraživačka djelatnost
Informacijski podsustav za upravljanje visokim učilištem	Accounts Payable and Receivable	Financije
	Investment Planning and management	Financije
	Financial and management accounting	Financije
	Financial Planning and Budgeting	Financije
	Budget execution	Financije
	Development/Fundraising	Financije
	Analytics	Financije
	General Ledger	Financije
	Billing, Tuition Fees	Studenti
Informacijski podsustav za upravljanje akademskim razvojem Informacijski podsustav za upravljanje visokim učilištem	Asset Management	Logistika
	Workforce and Promotion Planning and Management	Kadrovi
	Payroll Management	Kadrovi
	Staff Position Planning and Management	Kadrovi
	Academic Track Management	Kadrovi
Informacijski podsustav za potporne djelatnosti	Travel approval and processing	Kadrovi
	Document Management	Opći poslovi i javne isprave
	Procurement and supplying	Logistika
Ovi moduli su vezani uz	Infrastructural maintenance	Logistika
	Housing, Meals, Health	Studentski standard

studentski standard. U RH postoji organizacija Studentski centar koja preuzima većinu poslova vezanih uz studentski standard, te u suradnji s nadležnim Ministarstvom upravlja studentskim smještajem i prehranom.		
Iako fakulteti u sklopu svojih mogućnosti nastoje pomoću stipendija pomagati studentima, većina stipendija se daje iz drugih izvora (Ministarstvo, privatni izvori, poduzeća, zaklade).	Financial Aid and Loans	Studentski standard

Pristup usklađivanju potreba organizacije koje proizlaze iz poslovnih procesa i prilagodbom modula ne mora biti jedinstven za sva poslovna područja ili procese organizacije. Odabir pristupa ovisi o trenutnim potrebama i ciljevima organizacije, dostupnim resursima za uvođenje ICT-a u poslovanje i drugim faktorima. U tu svrhu su razrađeni pristupi usklađivanju potreba iz procesa i modula IS-a. Pristup usklađivanja je određen sa najmanje dva kriterija:

- 1) razinom promjene poslovnih procesa
- 2) razinom prilagodbe modula ERP sustava.

Razine promjene poslovnih procesa možemo jedinstveno iskazati pomoću tri razine:

- 1.1. Prilagodba procesa modulima IS-a,
- 1.2. Unapređenje poslovnih procesa i
- 1.3. Reinženjering poslovnih procesa.

Razine prilagodbe modula možemo opisati na sljedeći način:

- 2.1. Nema prilagodbe modula,
- 2.2. Minimalna promjena modula sa dogradnjom ili manjim izmjenama u matičnim podacima baze podataka, te
- 2.3. Značajna prilagodba modula koja može obuhvaćati sve aktivnosti dogradnje modula od izrade novih aplikacija do značajnih promjena u bazi podataka.

Moguće kombinacije razina pristupa promjenama poslovnih procesa i prilagodbe modula su prikazane matricom na slici 6.2., a daju 5 izvedivih pristupa.

		Razina prilagodbe modula		
		Nema prilagodbe modula	Minimalna promjena modula	Značajna prilagodba modula
Razina promjene procesa	Prilagodba procesa modulima IS-a	<i>1. Prilagodba poslovnih procesa neizmijenjenim modulima ERP sustava</i>	<i>2. Prilagodba poslovnih procesa minimalno izmijenjenim modulima</i>	
	Unapređenje poslovnih procesa		<i>3. Minimalne izmjene modula nakon unapređenja procesa</i>	<i>4. Značajna prilagodba modula prema unaprijeđenim procesima</i>
	Reinženjering poslovnih procesa			<i>5. Značajna prilagodba modula nakon reinženjeringa procesa</i>

Slika 6.2.: Matrica izvedivih pristupa promjenama poslovnih procesa i prilagodbe modula

Izvedivi pristupi imaju sljedeća svojstva:

1. pristup: Prilagodba poslovnih procesa neizmijenjenim modulima ERP sustava. Ovaj pristup je primjeren organizacijama koje nisu zadovoljne vlastitim poslovnim procesima i uz novi informacijski sustav žele preuzeti definicije i logiku poslovnih procesa najbolje prakse koji su ugrađeni u gotove module. Gotovi moduli se nabavljaju i implementiraju bez ikakvih izmjena.
2. pristup: Prilagodba poslovnih procesa minimalno izmijenjenim modulima ERP sustava. Prema ovoj kombinaciji pristupa još uvijek se radi o promjeni procesa prema funkcijama modula, preuzimanju modela najbolje prakse, ali ovaj put uz minimalne prilagodbe i intervencije u modulima i bazi podataka.
3. pristup: Minimalne izmjene modula nakon unapređenja procesa. Ovaj pristup podrazumijeva najprije intervencije u načinu obavljanja posla te nakon toga i u modulima ERP sustava prema izmijenjenim procesima.

4. pristup: Značajna prilagodba modula prema unaprijednim procesima je pristup koji zagovora najprije intenzivno promišljanje i uređivanje poslovnih procesa organizacije i nakon toga prilagodbu modula novim zahtjevima.
5. pristup: Značajna prilagodba modula nakon reinženjeringa procesa je pristup koji zahtijeva ekstenzivnu prilagodbu modula za procese nakon reinženjeringa (ili potpuno redizajnirane procese). Ovaj pristup zahtijeva najveća ulaganja, ali istovremeno obećava i najbolji povrat investicije jer onemogućava gubljenje strateške prednosti zbog jednakog IS-a kojeg potencijalno mogu imati konkurentne organizacije.

Odabir odgovarajućeg pristupa ne mora biti ograničen na jedinstven pristup cjelovitoj poslovnoj tehnologiji organizacije, već se ovisno o planiranom projektu implementacije ERP-a može odabrati za grupe ili pojedinačne procese, ali uzimajući u obzir rizik od neostvarivanja sinergijskog učinka. Pritom se kao sredstvo odabira odgovarajućeg pristupa može primijeniti McFarlanova portfolio matrica u izvornom obliku ili izmijenjenim kriterijima procjene značaja karakteristika procesa ili tehnologije. Detaljna razrada i doprinos iz rezultata rada na ovoj temi je objavljen u znanstvenom članku i prezentiran na znanstvenoj konferenciji The second symposium on business informatics in central and eastern Europe 2011.

7. Osnovni koncepti ERP sustava visokih učilišta

7.1. Polazna teza o sličnosti koncepata

ERP sustavi su prvotno razvijani za profitno orijentirane organizacije, te su bili namijenjeni potpori poslova proizvodnje. Iako su vremenom evoluirali u informacijske sustave koji se primjenjuju za potporu poslovanju i u drugim djelatnostima, pretpostavlja se da su neki osnovni koncepti i dalje ostali temelj funkcionalnosti ERP sustava.

S druge strane, specifični procesi (ili poslovne operacije) i organizacija koji određuju sustav planiranja i upravljanja resursima visokih učilišta, ukazuju na to da ERP sustavi visokih učilišta imaju i vlastite jedinstvene koncepte koji nisu prisutni u drugim ERP sustavima. To znači da se sustavi planiranja i upravljanja resursima visokim učilištima ne mogu promatrati kao podvrsta već postojećih ERP sustava, već da su u ontološkom smislu posebna klasa sustava planiranja i upravljanja resursima, te ih kao takve valja i posebno istraživati.

Dakle, polazna hipoteza koju se želi dokazati je da se sustavi planiranja i upravljanja resursima visokih učilišta strukturno i semantički temelje na osnovnim konceptima ERP sustava, ali istovremeno imaju i vlastite koncepte koji ih u ontološkom smislu čine posebnom klasom takvih sustava.

Kako bi se istražila te potvrdila ili opovrgnula navedena teza, najprije je potrebno definirati osnovne koncepte, zatim provjeriti jesu li koncepti klasičnog ERP sustava prisutni u ERP sustavima u visokim učilištima, odnosno postoje li specifični koncepti ERP sustava za visoka učilišta koji se ne mogu prepoznati ili smatrati sličnim s već postojećim konceptima klasičnih ERP sustava. Drugim riječima, da bismo dokazali da sustavi planiranja i upravljanja resursima visokih učilišta imaju i vlastite koncepte koji ih u ontološkom smislu čine posebnom klasom ERP sustava, moramo dokazati da postoji skup koncepata ERP sustav visokih učilišta koji se strukturno i semantički temelje na osnovnim konceptima ERP sustava, a nakon toga da postoje koncepti ERP sustava koji nisu dio tog skupa.

Pod sličnim konceptima će se smatrati koncepti kod kojih postoji semantička i strukturna sličnost. Provjera sličnosti počinje izradom modela osnovnih koncepata za proizvodni klasični ERP sustav i za ERP za potporu djelatnosti visokih učilišta. Modeli će biti izrađeni primjenom metode entiteti-veze-atributi (*engl. Entity Relationship Attribute Modeling*). Analogijom i primjenom postupaka za određivanje semantičke sličnosti će se zatim zaključivati o semantičkoj sličnosti između razmatranih koncepata u različitim područjima primjene, dok će se analiza strukturne sličnosti modela temeljiti na teoriji grafova. Na kraju će se izvesti zaključci o sličnosti modela osnovnih koncepata, odrediti primjenjivost osnovnih koncepata ERP sustava u specifičnom području planiranja i upravljanja resursima visokih učilišta, te potvrditi ili opovrgnuti teza o sličnosti primjene osnovnih koncepata ERP sustava u različitim djelatnostima.

Uspoređivanje grafičkih modela podataka i zaključivanje o semantičkim i strukturnim sličnostima može biti korisno i interesantno iz poslovnih i znanstvenih razloga. Ako uspoređivanjem istovrsnih podatkovnih modela utvrdimo da postoji skup semantički i strukturno sličnih podatkovnih objekata, onda taj skup objekata i svaki njegov podskup možemo koristiti kao predložak u novim poslovnim scenarijima i razvoju baze podataka informacijskog sustava, čime se može skratiti vrijeme projektiranja i razvoja informacijskog sustava. Ovo svojstvo višestruke primjene skupova podataka (*engl. Reusability*) zanimljivo je i u poslovnom i u znanstvenom smislu.

Sa znanstvenog stajališta ne mora zaključak analitičkog postupka biti najvažniji, već veći značaj može imati sam analitički postupak, odnosno način na koji se dolazi do zaključka i rezultata uspoređivanja. Postupak određivanja semantičke i strukturne sličnosti omogućuje provjeru vrijede li isti odnosi među konceptima u istovrsnim modelima izrađenim za različite poslovne domene, što onda može biti primjenjivo i za analizu i usporedbu drugih vrsta grafičkih modela kao što su metamodeli, konceptualni i referentni modeli podataka.

7.2. Modeli osnovnih koncepata ERP sustava

Modeli su prikazi odabranih relevantnih objekata iz realnog svijeta i odnosa koji među tim objektima vrijede, a predmet su razmatranja i interesa. Modeli se izrađuju pomoću koncepata koji mogu opisivati svojstva i/ili veze između koncepata. U informacijskim znanostima se u značajnoj mjeri razvijaju i koriste grafički modeli ili dijagrami. Grafički modeli se kao i svi drugi modeli izrađuju sa svrhom istraživanja, analize, simulacije ili reprezentacije, razvijaju se u skladu s pravilima izrade modela, a sadrže poznate, generalno prihvaćene ili dogovorno određene grafičke simbole za koncepte, veze i svojstva koncepata.

Model podataka je prikaz relevantnih podatkovnih objekata od interesa iz realnog svijeta, a definira oblik, strukturu i sadržaj buduće baze podataka informacijskog sustava. Bez obzira na metodu izrade, model obuhvaća:

1. Skup koncepata za modeliranje strukture podataka (npr. atributi, entiteti, veze);
2. Skup koncepata za modeliranje ograničenja i očuvanje konzistentnosti (npr. kardinalnost, preslikavanje, domena);
3. Skup koncepata za operacije nad podacima i promjene stanja.

Model podataka se izrađuje primjenom odabrane metode modeliranja podataka. Osnovne i široko primjenjive metode modeliranja podataka su temeljene na strukturnom i objektnom pristupu, a neke od njih su: modeliranje entiteta, njihovih veza i atributa (*engl. Entity Relationship Attribute Modeling, ili kraće ERA modeli*), IDEF1X, relacijski model, UML dijagrami (*Object, Class, Package Diagrams*).

Podatkovni model sa prethodno opisanim karakteristikama možemo uspoređivati s drugim istovrsnim podatkovnim modelima izrađenim za bilo koju drugu poslovnu domenu iz realnog svijeta te istraživati i utvrđivati sličnost između njih. Ovisno o obilježjima i elementima modela, možemo razlikovati semantičku i strukturnu sličnost modela i njihovih elemenata, te definirati metode, korake i postupke usporedbe.

Pod pojmom koncept ćemo smatrati svaki logički smislen objekt iz realnog svijeta koji ima sljedeća svojstva: 1) Predstavlja skup podataka o resursu ili poslovnoj transakciji, 2) primjenjuje se u određenom poslovnom kontekstu; 3) Realizira se pomoću jednog ili više međusobno povezanih entiteta; 4) Jednoznačno je opisan je atributima entiteta.

Primjer koncepta je Račun. Račun predstavlja skup podataka o poslovanju, točnije o poslovnoj transakciji prodaje, jer se ispostavlja kupcu/korisniku za pruženu uslugu ili prodani proizvod. U modelu se realizira pomoću entiteta Račun i Stavke računa. Minimalno je opisan atributima entiteta Račun (Broj računa, Identifikator izdavatelja računa, Identifikator primatelja računa, Datum izdavanja računa, Datum dospijeća računa) i atributima entiteta Stavke računa (Identifikator artikla, Količina). Generira ga proces prodati proizvod/uslugu, a koristi proces Naplatiti, Zaprimiti reklamaciju i drugi procesi.

Ovako definirani koncepti se mogu modelirati primjenom metoda za modeliranje podataka. U ovom slučaju je odabrana metoda modeliranja entiteta-veza-atributa (*engl. Entity Relationship Attribute Modeling, ili kraće ERA*). Entiteti koji imaju neka svojstva od interesa su objekti podatkovnog modela. Objekti opisuju jednu pojavu, a mogu biti jaki (postoje nezavisno od drugih objekata) i slabi (egzistencijalno i/ili identifikacijski ovise o jakom objektu). Atributi su svojstva koja detaljnije opisuju objekt, a mogu biti identifikatori (ključna svojstva koja jednoznačno opisuju entitet) i deskriptori (neključna svojstva).

Modeli na slikama u nastavku predstavljaju modele osnovnih koncepata ERP sustava za visoko obrazovanje (slika 7.1.) i ERP sustava za proizvodnu organizaciju (slika 7.2.). Radi preglednosti modela, nisu prikazani atributi entiteta, već samo nazivi entiteta.

Usporedbom modela želimo provjeriti dijele li modeli iste ili slične koncepte, odnosno imaju li vlastite specifične koncepte koji ih razlikuju od drugih modela? Već po različitom broju entiteta u modelima prikazanim na slikama 7.1. i 7.2. možemo zaključiti da postoje razlike u konceptima ERP-a proizvodnje i ERP-a za visoka učilišta. Kako razlika u broju entiteta u modelima može biti posljedica razine detaljizacije opisa entiteta i pristupa izradi modela, broj entiteta ne može biti osnovni kriterij po kojem bi se koncepti koji su prikazani u modelima uspoređivali. Usporedba se treba temeljiti na semantičkoj i strukturnoj sličnosti modela.

7.3. Određivanje semantičke sličnosti

Podatkovne modele koji su izrađeni za dvije različite poslovne domene iz realnog svijeta možemo uspoređivati, istraživati i utvrđivati njihovu sličnost samo ako su ti modeli izrađeni korištenjem iste metode modeliranja i ako oni koriste iste skupove koncepata za modeliranje strukture podataka, ograničenja i očuvanja konzistentnosti te operacije nad podacima. Ako ovaj preduvjet istovrsnosti modela i koncepata nije zadovoljen, modele je potrebno transformirati u zahtijevani oblik. Tako npr. ne možemo uspoređivati podatkovni ERA model pružanja bolničkih usluga i UML Object Diagram matičnog ureda. Budući da su modeli koncepata na slikama 7.1. i 7.2. izrađeni istom metodom modeliranja ovaj preduvjet je ispunjen.

Drugi minimalni preduvjet za usporedbu je analiza sadrže li modeli istoznačne ili analogne pojmove koje će predstavljati referentne točke za analizu i usporedbu modela. Ako ovaj preduvjet nije ispunjen, onda nema smisla uspoređivati modele u strukturnom smislu, jer veze između koncepata opisuju neusporedive odnose jednog i drugog modela.

Song, Johannesson i Bubenko [83] su istraživali kako određivanje semantičke sličnosti objekata može biti od koristi kod integracije podatkovnih modela u jedinstveni model, s ciljem smanjivanja redundantnosti podataka. Kashyap i Sheth [47] smatraju da je utvrđivanje semantičke sličnosti objekata podatkovnih modela ključno za podatkovnu interoperabilnost baza podataka nastalih prema tim modelima. Uzimajući u obzir postojeću literaturu određeni su kriteriji za određivanje semantičke sličnosti objekata podatkovnih modela. Prema tim kriterijima su predloženi postupci za određivanje

semantičke sličnosti, koji su detaljno razrađeni u objavljenom znanstvenom radu autorice u časopisu Journal of Information and Organizational Sciences 2010. godine.

U nastavku je u tablici 7.1. dan sažeti pregled predloženih postupaka provedbe određivanja semantičke sličnosti koncepata prikazanih pomoću podatkovnih modela.

Tablica 7.1.: Postupci određivanja semantičke sličnosti

Korak	Opis koraka	Izvršitelj	Rezultat
Određivanje semantičke sličnosti prema nazivu objekta	Razviti semantički rječnik koji sadrži po jedan stupac za svaki model podataka koji je obuhvaćen usporedbom (npr. ako su dva modela podataka u odnosu, semantički rječnik će se sastojati od dva stupca). U prvi stupac se dodaje prvi objekt modela s opisom značenja objekta. U drugi stupac se dodaje naziv objekata drugog modela ako je on homonim, skraćenica ili sinonim nazivu u prvom stupcu.	<i>Projektant informacijskog sustava</i>	Parovi objekata koji su semantički slični po nazivu objekata
Određivanje semantičke sličnosti prema atributima objekta	Uspoređivati attribute objekata dvaju modela te ako se oni podudaraju ili su identični onda ćemo smatrati da su objekti para slični po ključnim atributima.	<i>Projektant informacijskog sustava</i>	Parovi objekata koji su semantički slični po atributima objekata
Određivanje semantičke sličnosti statičkih modela koji opisuju kontekst korištenja objekata	Analizirati tipične poslovne scenarije korištenja podataka i analogijom zaključivati o mogućim parovima sličnih objekata. Temeljna pretpostavka ovog postupka jest da slični procesi koriste slične podatke na sličan način.	<i>Projektant informacijskog sustava u suradnji s poslovnim stručnjacima</i>	Parovi objekata koji su semantički slični po kontekstu korištenja
Određivanje semantičke sličnosti dinamike korištenja objekata	Pomoću dijagrama prijelaza stanja istražiti životni ciklus objekata. Tijekom životnog ciklusa objekata može se aktivirati početno stanje životnog ciklusa nekog drugog objekta te takve slučajeve valja također istražiti.	<i>Poslovni analitičar i projektant informacijskog sustava</i>	Parovi objekata koji imaju slične semantičke veze prema drugim objektima

Primjenom ovih metoda određivanja semantičke sličnosti pronađeni su parovi semantički sličnih objekata podatkovnih modela sa slika 7.1. i 7.2. Ti parovi su navedeni u tablici 7.2. na način da je u svakom retku prikazan jedan par semantički sličnih objekata. U prvom stupcu tablice je prikazan objekt podatkovnog modela koncepata ERP-a za visoka učilišta, u drugom njemu semantički sličan objekt podatkovnog modela

koncepta ERP-a za proizvodno poduzeće, a u trećem kriterij ili kriteriji po kojem je sličnost utvrđena.

Tablica 7.2.: Parovi semantički sličnih objekata podatkovnih modela

<i>Objekt VU</i>	<i>Objekt proizvodnog poduzeća</i>	Kriterij sličnosti
<i>Student</i>	<i>PoslPartner</i>	Par semantički sličnih objekata po kontekstu korištenja
<i>ZaposlenikVU</i>	<i>Zaposlenik</i>	Par semantički sličnih objekata po nazivu i atributima objekata
<i>Predmet</i>	<i>Artikl</i>	Par semantički sličnih objekata po kontekstu korištenja
<i>KontniPlan</i>	<i>KontniPlan</i>	Par semantički sličnih objekata po nazivu i atributima objekata
<i>Racun</i>	<i>Racun</i>	Par semantički sličnih objekata po nazivu i atributima objekata
<i>StavGlavKnjige</i>	<i>StavGlavKnjige</i>	Par semantički sličnih objekata po nazivu i atributima objekata
<i>Placanje</i>	<i>Placanje</i>	Par semantički sličnih objekata po nazivu i atributima objekata
<i>StavRacuna</i>	<i>StavRacuna</i>	Par semantički sličnih objekata po nazivu i atributima objekata
<i>StavRasporeda</i>	<i>StavRadNaloga</i>	Par semantički sličnih objekata prema vezama s drugim sličnim objektima i kontekstu korištenja
<i>ZauzeceOpreme</i>	<i>ZauzeceOpreme</i>	Par semantički sličnih objekata po nazivu i atributima objekata
<i>Proračun</i>	<i>Proračun</i>	Par semantički sličnih objekata po nazivu i atributima objekata
<i>PlanStav</i>	<i>PlanStav</i>	Par semantički sličnih objekata po nazivu i atributima objekata
<i>MedjusobUvjet</i>	<i>MatSastavnica</i>	Par semantički sličnih objekata prema vezama s drugim sličnim objektima
<i>ObliciAktivn</i>	<i>Operacije</i>	Par semantički sličnih objekata po kontekstu korištenja
<i>AkademKalen</i>	<i>RadKalendar</i>	Par semantički sličnih objekata po kontekstu korištenja
<i>Raspored</i>	<i>RadNalog</i>	Par semantički sličnih objekata po kontekstu korištenja
<i>Dvorane</i>	<i>Pogoni</i>	Par semantički sličnih objekata po kontekstu korištenja
<i>PlanAktivnosti</i>	<i>GlavPlanProiz</i>	Par semantički sličnih objekata po kontekstu korištenja
<i>UpisneKvote</i>	<i>PlanProizProg</i>	Par semantički sličnih objekata prema vezama s drugim sličnim objektima
<i>Studij</i>	<i>MogućeGrupe</i>	Par semantički sličnih objekata po kontekstu korištenja
<i>Oprema</i>	<i>Oprema</i>	Par semantički sličnih objekata po nazivu i atributima objekata
<i>UpisniList</i>	<i>ProdNalog</i>	Par semantički sličnih objekata prema vezama s drugim sličnim objektima
<i>UpisPredmeta</i>	<i>StavProdNaloga</i>	Par semantički sličnih objekata po kontekstu korištenja
<i>Zaposlenje</i>	<i>Zaposlenje</i>	Par semantički sličnih objekata po nazivu i atributima objekata
<i>RadMjesta</i>	<i>RadMjesta</i>	Par semantički sličnih objekata po nazivu i atributima objekata
<i>Cjenik</i>	<i>Cjenik</i>	Par semantički sličnih objekata po nazivu i atributima objekata
<i>ProgStudija</i>	<i>GrupaProizv</i>	Par semantički sličnih objekata po kontekstu korištenja

U tablici se nalazi 27 parova semantički sličnih objekata, što je manje od broja objekata na početnim modelima. Drugim riječima to znači da su nakon usporedbe semantičke sličnosti objekata i određivanja semantički sličnih objekata u početnim modelima preostali objekti koji nemaju svog semantički sličnog objekta-para u drugom modelu.

7.4. Određivanje strukturne sličnosti

Kada usporedba grafičkih modela ima smisla? Najprije treba utvrditi radi li se o istoj vrsti modela, odnosno dva modela koji sadrže iste koncepte. Ako to nije slučaj, najprije modele treba transformirati i prikazati istom metodom modeliranja. U analiziranom slučaju korištena je ERA metoda modeliranja podataka za izradu oba modela te je ovaj uvjet zadovoljen.

Sljedeći korak je analiza sadrže li modeli istoznačne ili analogne pojmove. Modeli istog oblika mogu opisivati proizvodnju ribarske mreže i izdavanje kredita, ali usporedba nema smisla jer značenje elemenata modela (u grafu čvorova i bridova) nije isto. Značenje objekata je analizirano kod određivanja semantički sličnih parova objekata podatkovnih modela, te su određeni parovi semantički sličnih objekata za koje treba provjeriti postoji li i strukturna sličnost. Time je zadovoljen i uvjet da se uspoređuju semantički slični pojmovi, odnosno objekti iz tablice 7.2. Podatkovne modele sa prethodno opisanim karakteristikama možemo uspoređivati s drugim istovrsnim podatkovnim modelima izrađenim za bilo koju drugu poslovnu domenu iz realnog svijeta te istraživati i utvrđivati sličnost između njih.

Postoji nekoliko formalnih metoda koje se mogu smatrati pogodnim za usporedbu grafičkih modela podataka. Vatanawood i Rivepiboon [90] i Yugopuspito i Araki [98] su se bavili primjenom Z notacije u modeliranju podataka, Keet [48] je uspoređivao konceptualne modele podataka primjenom deskriptivne logike, Mammar i Laleau [54] predlažu primjenu B-metode za usporedbu relacijskih UML, dok Kim Pilho spominje mogućnost prezentacije modela podataka pomoću grafova [73] i tvrdi da se „razmatranje modela podataka kao grafa može primjenjivati u slučajevima kada su informacije o povezanosti elemenata grafa ili topologija grafa važnija, ili jednako važna, kao i sami podaci”.

Prema Brumecu [11], baza podataka je skup neredundantnih zapisa o objektima od interesa, koji nastaju samo na jednom mjestu, a koriste se gdje god je to potrebno, te koji su povezani takvim vezama kakve su uspostavljene u stvarnosti između objekata koje ti zapisi predstavljaju. Budući da su struktura, ograničenja i operacije nad konceptima podatkovnih modela koji su podloga za bazu podataka prepoznati u strukturi, ograničenjima i operacijama nad čvorovima i bridovima grafova, pretpostavljam da je moguće podatkovne modele uspoređivati temeljem teorije grafova. Postupak treba obuhvaćati transformiranje modela u grafove (ili usmjerene grafove), usporedbu grafova, te zaključivanje temeljem utvrđivanja strukturne sličnosti među elementima grafova. Ako je moguće utvrditi strukturnu sličnost grafova, onda je za očekivati da i modeli podataka iz kojih su grafovi nastali, također imaju strukturno slične elemente. Prije opisa prijedloga postupka usporedbe strukturne sličnosti valja navesti definicije osnovnih pojmova i operacija koji se koriste u postupku usporedbe.

7.4.1. Definicije osnovnih pojmova

Prema teoriji grafova, posebna vrsta grafova su usmjereni grafovi ili digrafovi. Struktura, ograničenja i operacije digrafova su primjenjivi u analizi strukturne sličnosti drugih vrsta grafičkih modela, pa tako i modela podataka. Definicije pojmova su preuzete iz udžbenika Diskretna matematika s teorijom grafova (autori Divjak, Lovrenčić, [16]) i nastavnih materijala dostupnih na sustavu za upravljanje nastavnim materijalima i e-učenje [17].

Usmjereni graf ili digraf D je uređeni par (V, A) , pri čemu je V neprazni skup vrhova $\{v_1, v_2, \dots, v_n\}$ od D , a svaki element skupa A je uređeni par elemenata iz V , tj. $A \subseteq V \times V$. Elementi skupa A se zovu lukovi digrafa D . Kod digrafa, luk $v_i v_j$ je različit od luka $v_j v_i$ jer je važno koji je vrh početak, a koji je kraj. Digraf crtamo tako da nacrtamo pripadni graf i na svakom bridu se nacrtaju strelica koja je usmjerena prema drugom vrhu odgovarajućeg luka. Težinski graf je graf G čijem je svakom bridu e pridružen nenegativni broj $w(e)$ kojeg zovemo težina brida e .

Neka je D digraf sa skupom vrhova $\{v_1, v_2, \dots, v_n\}$. Definiramo da je a_{ij} jednak broju bridova koji povezuju vrhove v_i i v_j za $1 \leq i, j \leq n$, pri čemu je n broj sličnih objekata

podatkovnih modela. Matrica susjedstva digrafa D je kvadratna matrica $M = [m_{ij}]$ reda n , gdje je m_{ij} broj lukova kojima je početak u vrhu v_i , a kraj u vrhu v_j . Matrica M općenito ne mora biti simetrična matrica jer ako postoji luk $v_i v_j$, tada ne mora postojati i luk $v_j v_i$.

Graf H je podgraf grafa D , u oznaci $H \subseteq D$, ako je $V(H) \subseteq V(D)$ i $A(H) \subseteq A(D)$. Ako je $H \subseteq D$ i $H \neq D$, tada pišemo $H \subset D$ i kažemo da je H pravi podgraf od D . Ako je H podgraf od D , tada je D nadgraf od H . Podgraf H od D za koji je $V(H) = V(D)$ zove se razapinjući podgraf od G .

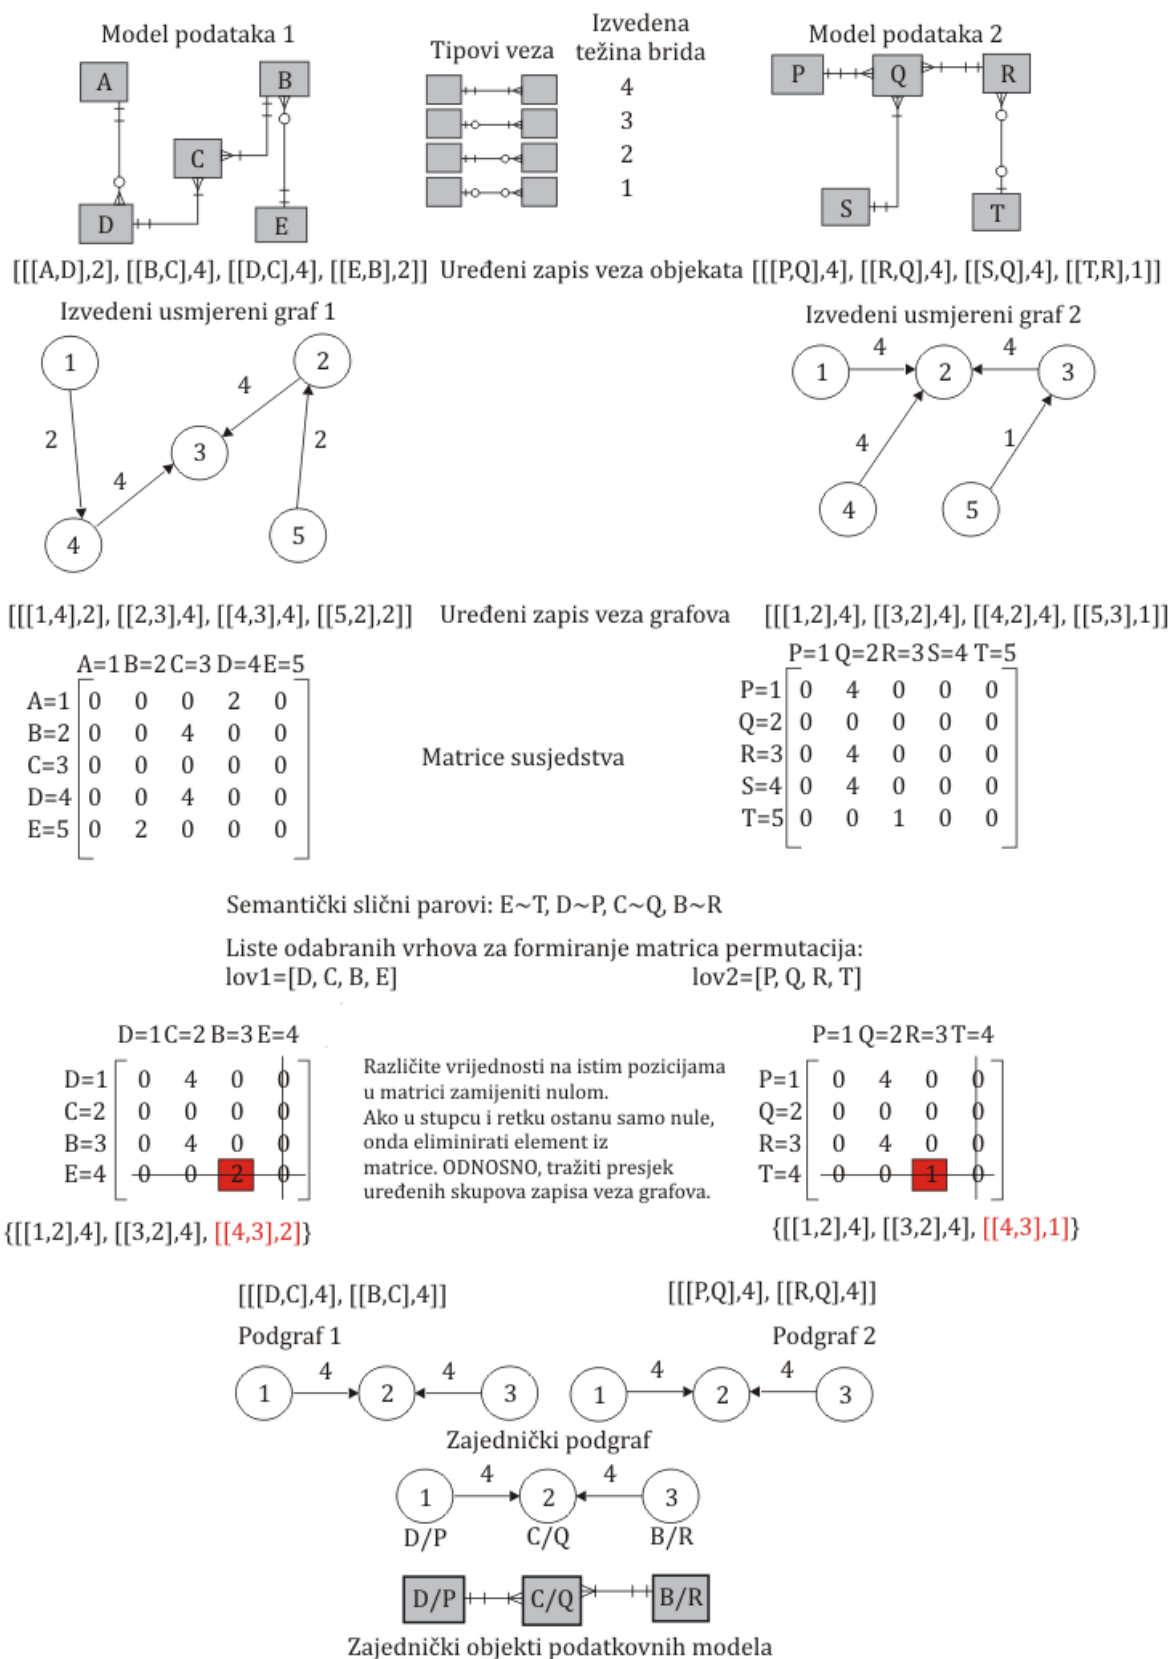
Neka su $D_1 = (V_1; A_1)$ i $D_2 = (V_2; A_2)$ digrafovi. Kažemo da su D_1 i D_2 izomorfni ako postoji barem jedna bijekcija $\varphi: V_1 \rightarrow V_2$ koja čuva susjednost i orijentaciju, odnosno ako se njihovi vrhovi mogu označiti tako da su im matrice susjedstva jednake. Dva digrafa s pripadnim matricama susjedstva A_1 i A_2 su izomorfni ako postoji matrica permutacije P takva da je $A_2 = PA_1P^T$.

Neka je $D = (V, A)$ digraf. Instupanj ili ulazni stupanj vrha $v \in V$ je broj $d^-(v)$ lukova u D koji imaju kraj u vrhu v . Outstupanj ili izlazni stupanj vrha $v \in V$ je broj $d^+(v)$ lukova u D koji imaju početak u vrhu v . Ako su D_1 i D_2 izomorfni digrafovi, tada vrijedi: D_1 i D_2 imaju isti broj vrhova, D_1 i D_2 imaju isti broj lukova te D_1 i D_2 imaju iste nizove instupnjeva i iste nizove outstupnjeva odgovarajućih vrhova.

7.4.2. Postupak određivanja strukturne sličnosti istovrsnih grafičkih modela

Bez obzira na metodu modeliranja, za izgradnju podatkovnog modela treba odabrati skup koncepata za modeliranje strukture podataka (npr. atributi, entiteti, veze...), skup koncepata za modeliranje ograničenja i očuvanje konzistentnosti (kardinalnost, preslikavanje, domena) te skup koncepata za operacije nad podacima i promjene stanja (selekcija, unija, ...). Ovi skupovi koncepata se mogu prepoznati i prevesti u strukture, ograničenja i operacije čvorova (vrhova) i njihovih lukova (ili bridova) u grafovima.

Osnovna ideja utvrđivanja strukturne sličnosti objekata podatkovnih modela primjenom teorije grafova je na slici 7.3. prikazana tehnikom sadržajno obilatog crtanja (engl. rich-picture). Na slici je pojednostavljeno prikazan postupak utvrđivanja strukturne sličnosti koji je detaljno opisan i razrađen u nastavku. Slika 7.3. dakle ne prikazuje cjelovit postupak, već samo ilustrira ideju prema kojoj je detaljan postupak razrađen.



Slika 7.3.: Pojednostavljeni grafički prikaz postupka utvrđivanja strukturne sličnosti podatkovnih modela

Postupak usporedbe za utvrđivanje strukturne sličnosti istovrsnih grafičkih modela bi se trebao izvesti kroz tri faze s pripadnim koracima:

1) Priprema grafičkih modela,

- Odabir logičkih modela podataka za usporedbu.
- Identifikacija veza objekata podatkovnih modela.
- Izrada kataloga objekata podatkovnih modela.
- Izrada kataloga tipova veza podatkovnih modela.
- Kreiranje liste lukova početnih grafova.
- Identifikacija parova semantički sličnih objekata.

2) Primjena algoritma usporedbe grafova,

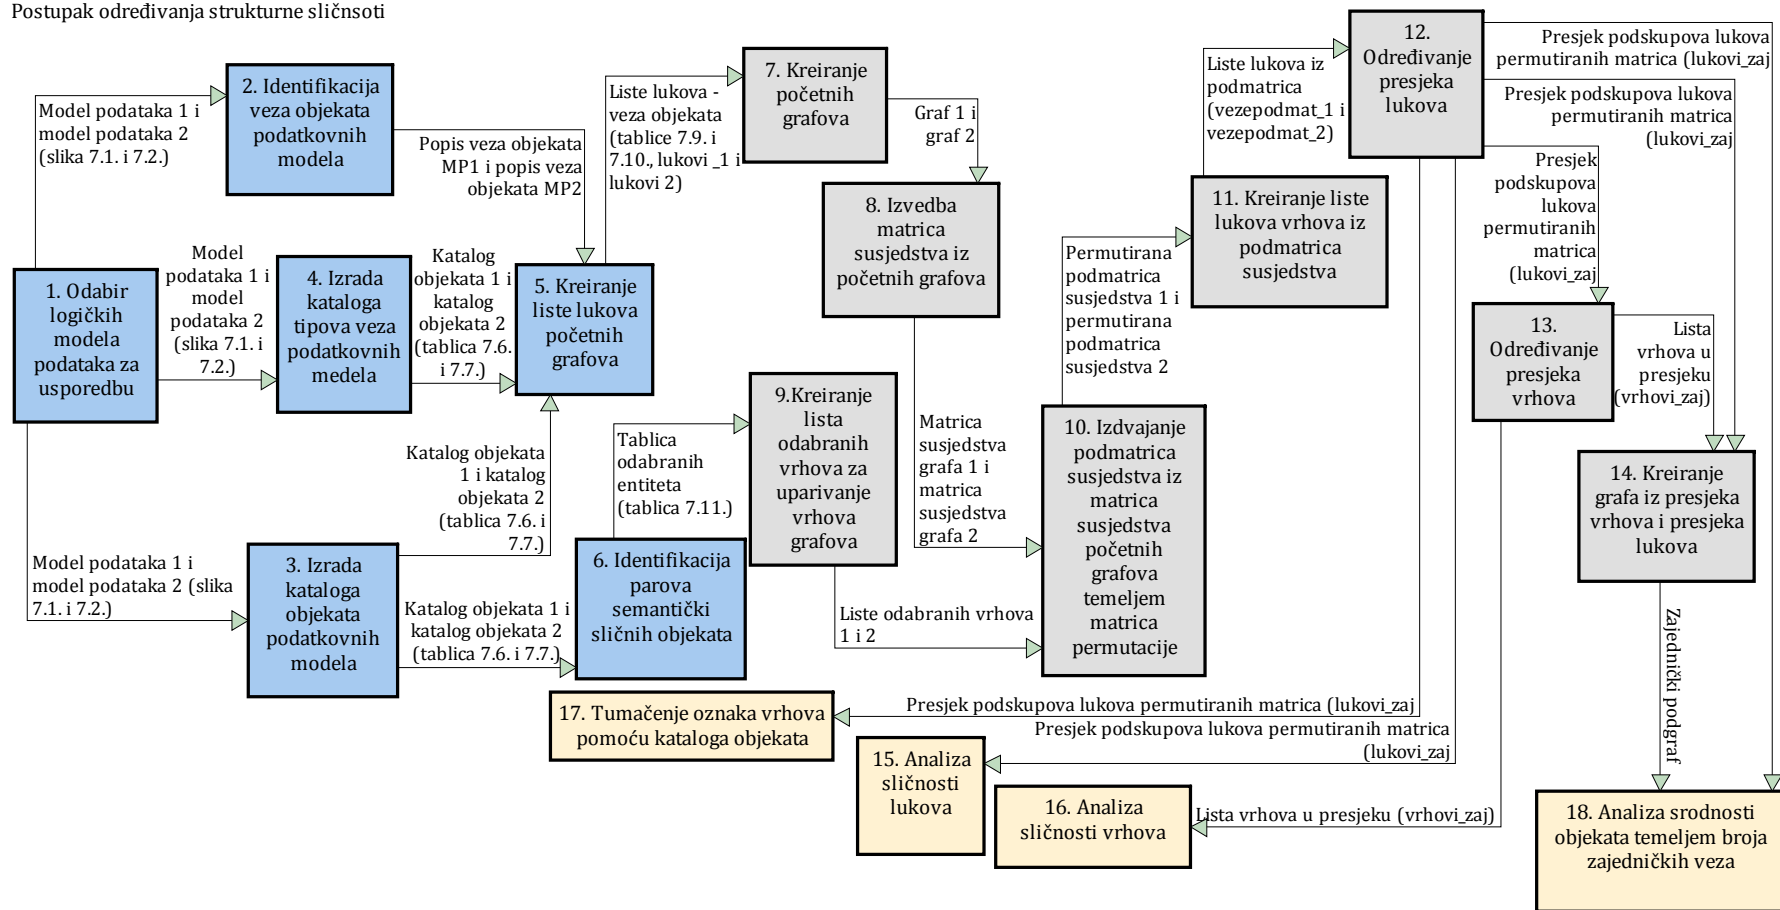
- Kreiranje početnih grafova.
- Izvedba matrica susjedstva iz početnih grafova.
- Kreiranje liste odabranih vrhova za uparivanje vrhova grafova.
- Izdvajanje podmatrica susjedstva iz matrica susjedstva početnih grafova temeljem lista odabranih vrhova.
- Kreiranje liste lukova vrhova iz podmatrica susjedstva.
- Određivanje presjeka lukova.
- Određivanje presjeka vrhova.
- Kreiranje grafa iz presjeka vrhova i presjeka lukova.

3) Tumačenje rezultata usporedbe

- Analiza sličnosti lukova.
- Analiza sličnosti vrhova.
- Tumačenje oznaka vrhova pomoću kataloga objekata.
- Analiza srodnosti objekata temeljem broja zajedničkih veza.

Faze obuhvaćaju korake 1 do 18. Koraci su međusobno povezani na način da su rezultati jednog ili više koraka ulazi u neki drugi korak. Zato je najprije dan grafički prikaz postupka određivanja strukturne sličnosti (slika 7.4.), nakon toga je postupak opisan u tablici (tablica 7.3.), zatim razrađen i proveden u nastavku.

Postupak određivanja strukturne sličnosti



Slika 7.4.: Grafički prikaz faza i koraka postupka određivanja strukturne sličnosti istovrsnih grafičkih modela

Tablica 7.3.: Faze i koraci postupka određivanja strukturne sličnosti grafičkih modela

Faze	Koraci	Rezultat
Priprema grafičkih modela	1. Odabir logičkih modela podataka za usporedbu. Modeli trebaju biti usporedivi, što znači da moraju biti izrađeni istom metodom modeliranja i obuhvaćati usporedive objekte.	Model podataka 1 (slika 7.1.) Model podataka 2 (slika 7.2.)
	2. Identifikacija veza objekata podatkovnih modela. Izraditi popis veza entiteta podatkovnih modela u sljedećem obliku: ishodišni entitet čiji se identifikator referencira u odredišnom entitetu, tip veze prema odredišnom entitetu, odredišni entitet.	Popis veza entiteta modela podataka 1 (tablica 7.4.) Popis veza entiteta modela podataka 2 (tablica 7.5.)
	3. Izrada kataloga objekata podatkovnih modela. Izraditi abecedne kataloge entiteta (objekata) podatkovnih modela s indeksima od 1 do N/M, gdje je N/M ukupni broj entiteta modela podataka. Svakom entitetu se dodjeljuje identifikacijski broj, koji će predstavljati broj čvora u usmjerenom grafu.	Katalog entiteta modela podataka 1 duljine N (tablica 7.6.) Katalog entiteta modela podataka 2 duljine M (tablica 7.7.)
	4. Izrada kataloga tipova veza podatkovnih modela. Izraditi katalog relevantnih tipova veza entiteta (objekata) podatkovnih modela. Svaki tip veze može predstavljati kombinaciju svojstava veze kao što su tip povezivanja (primarni ili vanjski ključ), opcionalnost, učestalost i druga svojstva veze koja su relevantna. Svakom tipu veze se dodjeljuje brojana oznaka koja će se kasnije koristiti kao težina luka.	Katalog tipova veza (tablica 7.8.)
	5. Kreiranje liste lukova početnih grafova. Popis veza entiteta prevesti u oblik primjeren za formiranje usmjerenog grafa: $[[X,Y],Z]$; X – broj ishodišnog entiteta iz kojeg se preuzima identifikator, odabire se iz kataloga entiteta prvog modela podataka, u grafu će to biti ishodišni vrh luka Y – broj odredišnog entiteta u kojem se preuzima identifikator od X, odabire se iz kataloga entiteta drugog modela podataka, u grafu će to biti odredišni vrh luka Z predstavlja oznaku tipa veze, odabire se iz kataloga veza entiteta, u grafu će to biti težina luka koji ide iz X u Y.	Lista veza entiteta /lista lukova modela podataka 1 (krajnji desni stupac tablice 7.9., lukovi_1) Lista veza entiteta /lista lukova modela podataka 2 (krajnji desni stupac tablice 7.10., lukovi_2)
	6. Identifikacija parova semantički sličnih objekata. Kreirati dvostupčanu tablicu odabranih entiteta koja u svakom retku obuhvaća par entiteta prvog i drugog podatkovnog modela za koje se pretpostavlja da su semantički slični. Redoslijed redaka nije važan.	Tablica odabranih entiteta maksimalne duljine K, pri čemu je $K=N$ (ako je $N<M$) ili $K=M$ (ako je $M<N$) (tablica 7.11.)

Primjena algoritma usporedbe grafova	<p>7. Kreiranje početnih grafova.</p> <p>Provesti postupak prevođenja grafičkih modela u usmjerene grafove. Iz popisa veza u formatu $[[X,Y],Z]$ kreirati usmjerene težinske grafove: graf 1 koji prikazuje vrhove i lukove izvedene iz veza entiteta prvog modela podataka i graf 2 koji prikazuje vrhove i lukove izvedene iz veza entiteta drugog modela podataka.</p>	<p>Graf 1 sa N vrhova i maksimalno N^2 lukova (graf_1)</p> <p>Graf 2 sa M vrhova i maksimalno M^2 lukova (graf_2)</p>
	<p>8. Izvedba matrica susjedstva iz početnih grafova.</p> <p>Iz grafa 1 kreirati kvadratnu matricu susjedstva 1 veličine $N \times N$, iz grafa 2 kreirati matricu susjedstva 2 veličine $M \times M$</p>	<p>Matrica susjedstva grafa 1 reda N (mat_1)</p> <p>Matrica susjedstva grafa 2 reda M (mat_2)</p>
	<p>9. Kreiranje lista odabranih vrhova za uparivanje vrhova grafova.</p> <p>Prema tablici odabranih semantički sličnih entiteta kreirati liste odabranih vrhova (lov). Lista odabarnih vrhova je zapravo permutacija prema kojoj će se formirati podmatrice susjedstva tj. matrica permutacije prema permutaciji zadanoj u listi odabranih vrhova. Za svaki entitet iz prvog stupca pronaći njegovu oznaku iz kataloga entiteta prvog modela podataka, a zatim staviti broj u lov 1. Zatim za svaki entitet iz drugog stupca pronaći njegovu oznaku iz kataloga entiteta drugog modela podataka a zatim staviti broj u lov 2.</p>	<p>Lista odabranih vrhova 1 (lov_1)</p> <p>Lista odabaranih vrhova 2 (lov_2)</p>
	<p>10. Izdvajanje podmatrica susjedstva iz matrica susjedstva početnih grafova temeljem lista odabranih vrhova.</p> <p>Eliminirati retke i stupce u matricama susjedstva grafova 1 i 2 koji se ne nalaze u listama odabranih vrhova, jer su neusporedivi. Prema lov 1 i 2 permutirati retke i stupce matrica susjedstva grafa 1 i grafa 2. Preostali vrhovi matrica susjedstva su usporedivi prema oznakama vrhova i lukova s težinama.</p>	<p>Permutirana kvadratna podmatrica susjedstva grafa 1 reda K (podmat_1)</p> <p>Permutirana kvadratna podmatrica susjedstva grafa 2 reda K (podmat_2)</p>
	<p>11. Kreiranje liste lukova vrhova iz podmatrica susjedstva.</p> <p>Iz permutiranih kvadratnih podmatrica susjedstva 1 i 2 izdvojiti sve lukove grafa 1 i grafa 2 u obliku $[[X,Y],Z]$ u podskupove lukova 1 i 2. Zbog permutacije redaka i stupaca isti broj vrha će imati entiteti podatkovnih modela koji su semantički slični.</p>	<p>Podskup lukova grafa 1 prema permutiranoj matrici susjedstva 1 (vezepodmat_1)</p> <p>Podskup lukova grafa 2 prema permutiranoj matrici susjedstva 2 (vezepodmat_1)</p>
	<p>12. Određivanje presjeka lukova.</p> <p>U podskupovima lukova su zapisane veze između semantički sličnih objekata s uparenim bročanim oznakama vrhova. Među elementima podskupova lukova treba pronaći presjek. Time se utvrđuju lukovi istih težina između vrhova s istim oznakama.</p>	<p>Presjek podskupova lukova permutiranih matrica susjedstva 1 i 2 (lukovi_zaj)</p>
	<p>13. Određivanje presjeka vrhova.</p> <p>Iz presjeka eliminirati vrhove koji nemaju niti jedan ulazni ili izlazni luk. Ti vrhovi predstavljaju entitete za koje je</p>	<p>Podgrafovi početnih grafova (vrhovi_zaj)</p>

Tumačenje rezultata usporedbe	<p>pretpostavljena semantička sličnost, ali nije utvrđena strukturna sličnost analizom veza. Preostali vrhovi su zajednički, odnosno to predstavljaju semantički sličan objekt s bar jednom strukturno sličnom vezom prema nekom drugom objektu na oba uspoređena modela.</p>	
	<p>14. Kreiranje grafa iz presjeka vrhova i presjeka lukova.</p> <p>Kreiranje zajedničkog podgraфа na temelju elemenata iz presjeka lukova (lukovi_zaj) i presjeka vrhova (vrhovi_zaj). Vrhovi na zajedničkom podgraфу predstavljaju semantički i strukturno slične objekte uspoređenim podatkovnih modela, a lukovi prikazuju tip veze koji postoji među sličnim objektima.</p>	Zajednički podgraf (grafPresjekaLukova, slika 7.6.)
	<p>15. Analiza sličnosti lukova.</p> <p>Izračunati sličnost podatkovnih modela s obzirom na broj lukova u početnim modelima i zajedničkom modelu.</p>	<p>Mjera sličnosti lukova prvog podatkovnog modela prema drugom</p> <p>Mjera sličnosti lukova drugog podatkovnog modela prema prvom</p>
	<p>16. Analiza sličnosti vrhova.</p> <p>Izračunati sličnost podatkovnih modela s obzirom na broj vrhova u početnim modelima i zajedničkom modelu.</p>	<p>Mjera sličnosti vrhova prvog podatkovnog modela prema drugom</p> <p>Mjera sličnosti vrhova drugog podatkovnog modela prema prvom</p>
	<p>17. Tumačenje oznaka vrhova pomoću kataloga objekata.</p> <p>Izraditi listu semantički i strukturno sličnih entiteta početnih grafova i zajedničkog podgraфа temeljem oznaka iz grafova i naziva svakog entiteta u početnom modelu.</p>	<p>Vrhovi podgraфа odabranih semantički sličnih objekata prvog modela u zajedničkom podgraфу</p> <p>Vrhovi podgraфа odabranih semantički sličnih objekata drugog podatkovnog modela u zajedničkom podgraфу</p>
	<p>18. Analiza srodnosti objekata temeljem broja zajedničkih veza.</p> <p>Preostali vrhovi u presjeku predstavljaju entitete za koje je pretpostavljena semantička sličnost i temeljem nje dokazana strukturna sličnost s bar jednim drugim entitetom. Vrhovi i lukovi u presjeku čine novi zajednički graf koji je izomorfan minimalno jednom podgraфу graфа 1 i minimalno jednom podgraфу graфа 2.</p>	Srodnost entiteta u početnim i zajedničkom modelu (tablica 7.14.)

U nastavku je prikazana provedba svakog koraka postupka.

7.4.2.1. Priprema grafičkih modela

Početna faza postupka usporedbe za utvrđivanje strukturne sličnosti istovrsnih grafičkih modela se sastoji od 6 koraka, koji su detaljno opisani i provedeni u nastavku.

Korak 1: Odabir logičkih modela podataka za usporedbu. Za usporedbu su odabrani logički modeli podatka prikazani na prethodnim slikama 7.1. i 7.2.

Korak 2: Identifikacija veza objekata podatkovnih modela.

Za odabrane modele podatka je potrebno izraditi popis veza entiteta podatkovnih modela u sljedećem obliku: ishodišni entitet čiji se identifikator referencira u odredišnom entitetu, tip veze prema odredišnom entitetu, odredišni entitet (tablice 7.4. i 7.5.).

Podatkovni modeli su izrađeni u programskom alatu Cool:Biz. Pomoću alata su izrađena i izvješća o vezama modela podataka koje obuhvaćaju i popis svih veza entiteta obuhvaćenih modelom. Tablice svih veza podatkovnih modela iz izvješća su prikazane u tablicama 7.4. i 7.5.

Tablice 7.4. i 7.5. su drukčiji način zapisa modela podataka sa slika 7.1. i 7.2., a potrebne su kako bismo modele podataka preveli u usmjerene grafove, koje onda možemo uspoređivati operacijama nad grafovima.

U prvom stupcu tablice je naveden entitet čiji se atribut referencira u odredišnom entitetu. Srednji stupac obuhvaća naziv veze i učestalost referenciranja, a čita se s lijeva na desno do brojčane oznake te s desna na lijevo prema ishodišnom entitetu.

Tablica 7.4.: Popis veza objekata podatkovnog modela za visoka učilišta

Ishodišni entitet	Veza	Odredišni entitet
Student	se može <0..M> se odnosi na <1..1>	UpisStudenta
Predmet	se polaže <0..M> se odnosi na <1..1>	IspitniRok
IspitniRok	vrijedi ako postoji <0..M> se odnosi na <1..1>	PrijavaIspita
Student	pristupa ispitu <0..M> se odnosi na <1..1>	PrijavaIspita
Predmet	se izvodi prema <0..M> obuhvaća <1..1>	StavRasporeda
Predmet	imati preduvjet <0..M> se odnosi na <1..1>	MedjusobUvjet
AkademKalen	definira vrijeme <0..M> je određen <1..1>	StavRasporeda
Dvorane	definira prostorna ograničenja <0..M> je određen <1..1>	StavRasporeda
Institucija	je primatelj <0..M> se odnosi na <1..1>	Racun
Predmet	može biti izvor <0..M> može biti u području <0..1>	TemaRada
Oprema	se koristi za izvedbu <0..M> koristi <1..1>	ZauzeceOpreme
StavRasporeda	koristi <0..M> se odnosi na <1..1>	ZauzeceOpreme
Racun	je temelj za <0..M> se provodi na temelju <1..1>	Placanje
ZaposlenikVU	može biti mentor <0..M> je zadana od <1..1>	TemaRada
Student	je autor <0..M> je izrađen od <1..1>	TemaRada
Student	može biti primatelj <0..M> se odnosi na <0..1>	Racun
ZaposlenikVU	sudjeluje u izvedbi <0..M> izvodi <1..M>	StavRasporeda
ObliciAktivn	su odabrani u <0..M> se odnosi na <0..1>	StavRasporeda
Studij	se odnose na <1..M> je ograničen <0..1>	UpisneKvote
StudPrava	se mogu dodijeliti <0..M> jest tipa <0..1>	PriznStudPrava
Zahtjev	pokreće otvaranje <0..M> je pokrenut na temelju <1..1>	Postupak
AktivnPostupka	se obavljaju za rješavanje <0..M> je određen završetkom <1..1>	StatusPostupka
ZaposlenikVU	ima <0..M> se odnosi na <1..1>	IzborUZvanje
Student	predaje <0..M> je predao <1..1>	Zahtjev
Student	može imati <0..M> se odnose na <1..1>	ObvezeStud
ObrazProfili	su definirani za <0..M> rezultira <1..1>	Studij
KontniPlan	definira <0..M> se knjiže prema <1..1>	StavGlavKnjige
ZaposlenikVU	zadaje <0..M> je zadan od <1..1>	IspitniRok
ZaposlenikVU	je nositelj <0..M> je prijavljen od <1..1>	Projekt
ZaposlenikVU	evidentira sate za <0..M> se odnosi na <1..1>	RadNaProjektu
VrstaProj	definira <0..M> jest tipa <1..1>	Projekt
ZaposlenikVU	je autor <0..M> je napisan od <1..1>	Autori
Radovi	ima <0..M> je vezan uz <1..1>	Autori
KategRada	opisuje vrstu <0..M> jest tipa <1..1>	Radovi
Studij	ima <0..M> pripada <1..1>	ISHUcenjProg
IshUcenja	su vezani <0..M> jest tipa <1..1>	ISHUcenjProg
IshUcenja	pripada <0..M> ima <1..1>	IshUcenjPredmeta
Institucija	može biti <0..M> jest <1..1>	NositeljProg
Studij	može imati <0..M> se odnosi na <1..1>	NositeljProg
Raspored	može imati <0..M> pripada <1..1>	StavRasporeda
Studij	ima svoj <0..M> pripada <1..1>	Raspored
AkademKalen	opisuje <0..M> se provodi prema <1..1>	PlanAktivnosti
ZaposlenikVU	može imati <0..M> se odnosi na <1..1>	Zaposlenje
RadMjesta	opisuje <0..M> se odnosi na <1..1>	Zaposlenje
ZaposlenikVU	ima <0..M> se odnosi na <1..1>	PlanAktivnosti
Student	može upisati <0..M> se odnosi na <1..1>	UpisniList
UpisniList	ima <0..M> se odnose na <1..1>	UpisPredmeta
Predmet	se upisuje <0..M> se odnosi na <1..1>	UpisPredmeta
AkademKalen	određuje <0..M> pripada <1..1>	IspitniRok
KontniPlan	određuje <0..M> su tipa <1..1>	PlanStav

Predmet	može imati <0..M> se odnosi na <0..1>	PlanAktivnosti
Postupak	može imati <0..M> se odnosi na <1..1>	StatusPostupka
StudObveze	se mogu dodijeliti <0..M> su tiao <1..1>	ObvezeStud
Zvanja	mogu biti dodijeljena <0..M> se odnosi na <1..1>	IzborUZvanje
Uvjeti	su ocijenjeni <0..M> su za <1..1>	IspunjUvjeta
Student	može imati <0..M> se odnosi na <1..1>	PriznStudPrava
IzborUZvanje	je referenciran u <0..M> se odnosi na <1..1>	IspunjUvjeta
ObliciAktivn	su navedeni u <0..M> jest tipa <1..1>	PlanAktivnosti
Racun	je temelj za <0..M> se odnosi na <0..1>	StavGlavKnjige
Studij	je odabran <0..M> se odnosi na <1..1>	UpisStudenta
Projekt	ima aktivnosti <0..M> se odnosi na <1..1>	RadNaProjektu
ZnanPodrucje	klasificira <0..M> pripada <1..1>	Radovi
ZnanPodrucje	klasificira <0..M> pripada <1..1>	Projekt
Predmet	Ima <0..M> se odnose na <1..1>	IshUcenjPredmeta
Racun	ima <0..M> pripadaju <1..1>	StavRacuna
AkademKalen	je referenciran u <0..M> se odnose na <1..1>	UpisneKvote
Usluge	ima <0..M> se odnosi na <1..1>	Cjenik
Usluge	se koristi za <0..M> jest tipa <1..1>	StavRacuna
RadAktivn	su navedene <0..M> su tipa <1..1>	RadNaProjektu
PrijavaIspita	ima <0..M> opisuje <1..1>	StatusPrijavIspita
ZaposlenikVU	unos <0..M> je unesen od <1..1>	StatusPrijavIspita
Predmet	ima statusa u programu studija <0..M> se odnosi na <1..1>	ProgStudija
PutNal	je kreiran za <1..M> može imati <0..1>	ZaposlenikVU
PutNal	može imati <0..M> pripada <1..1>	StavPutNal
PutTrosk	opisuje <0..M> jest tipa <1..1>	StavPutNal
Proračun	ima <0..M> pripadaju <1..1>	PlanStav
Predmet	može biti preduvjet <0..M> se odnosi <1..1>	MedjusobUvjet
KontniPlan	je nadređen <0..M> je tipa <1..1>	KontniPlan

Tablica 7.5.: Popis veza objekata podatkovnog modela za proizvodna poduzeća

Ishodišni entitet	Veza	Odredišni entitet
Zaposlenik	je izdao <0..M> je kreirana od <1..1>	Zahtjevnica
Zahtjevnica	može biti temelj za <0..M> se temelji na <0..1>	Narudžba
PoslPartner	je naručio artikle u <0..M> se odnosi na <1..1>	ProdNalog
Artikl	se sastoji od <0..M> opisuje <1..1>	MatSastavnica
PoslPartner	je isporučio robu prema <0..M> potvrđuje isporuku od <1..1>	Primka
PoslPartner	prima robu <0..M> glasi na <1..1>	Otpremnica
StatusNaloga	opisuje <0..M> ima <1..1>	RadNalog
Ovlastenja	mogu biti didijeljena <0..M> su tipa <1..1>	dodjelOvlas
Zaposlenik	može imati <0..M> se odnosi na <1..1>	dodjelOvlas
RadMjesta	određuje <0..M> je za <1..1>	Zaposlenje
Zaposlenik	ima <0..M> se odnosi na <1..1>	Zaposlenje
RadNalog	ima <0..M> pripada <1..1>	StavRadNaloga
Racun	ima <0..M> pripada <1..1>	StavRacuna
Zahtjevnica	ima <0..M> pripada <1..1>	StavZahtjev
ObliciSuradnje	je ugovoren u <0..M> je određen <1..1>	UgovObliSurad
KontniPlan	definira <0..M> se knjiži prema <1..1>	StavGlavKnjige
RadKalendar	se koristi za <0..M> je ograničen <1..1>	StavRadNaloga
Artikl	se zaprima <0..M> obuhvaća <1..1>	StavPrim
Primka	može imati <0..M> pripada <1..1>	StavPrim
Artikl	je naveden u <0..M> se odnosi na <1..1>	StavOtprem
Artikl	je naveden u <0..M> se odnosi na <1..1>	StavIzdat

Narudzba	ima <0..M> pripada <1..1>	StavNarudz
Artikl	je naveden u <0..M> jest tipa <1..1>	StavNarudz
Artikl	je naveden u <0..M> definira cijenu <1..1>	Cjenik
Racun	se knjiži <1..M> se odnosi na <0..1>	StavGlavKnjige
Zaposlenik	je izvršitelj <0..M> postupa prema <1..1>	StavRadNaloga
ProdNalog	ima <0..M> pripada <1..1>	StavProdNaloga
KontniPlan	definira <0..M> se odnosi na <1..1>	PlanStav
PoslPartner	prima <0..M> glasi na <1..1>	Narudzba
Artikl	se planira proizvesti u <0..M> se odnosi na <1..1>	GlavPlanProiz
Artikl	pripada <0..M> se odnosi na <1..1>	GrupaProizv
MogućeGrupe	definiraju <0..M> se odnosi na <1..1>	GrupaProizv
MogućeGrupe	se navode u <0..M> se odnosi na <1..1>	PlanProizProg
RadKalendar	opisuje <0..M> se odnosi na <1..1>	PlanProizProg
Operacije	opisuju <0..M> obuhvaća <1..1>	GlavPlanProiz
StavRadNaloga	koristi <0..M> se odnosi na <1..1>	ZauzećeOpreme
RadKalendar	opisuje <0..M> se provodi prema <1..1>	GlavPlanProiz
Artikl	je naveden u <0..M> su tipa <1..1>	StavRacuna
OrgJedinica	je primatelj <0..M> glasi na <1..1>	Primka
Primka	se knjiži <0..M> se odnosi na <1..1>	StavGlavKnjige
OrgJedinica	otprema pomoću <0..M> je izdana od <1..1>	Otpremnica
OrgJedinica	izdaje <0..M> je izdana <1..1>	Izdatnica
Izdatnica	se knjižina <0..M> se odnosi na <1..1>	StavGlavKnjige
Racun	je temelj za <0..M> se odnosi na <1..1>	Plaćanje
Artikl	je naveden u <0..M> se odnosi na <1..1>	StavRadNaloga
Artikl	je naveden u <0..M> je tipa <1..1>	StavZahtjev
Operacije	su navedene u <0..M> su određene <1..1>	StavRadNaloga
Pogoni	je neveden u <0..M> se izvodi u <1..1>	StavRadNaloga
Izdatnica	ima <0..M> pripada <1..1>	StavIzdat
Otpremnica	ima <0..M> pripada <1..1>	StavOtprem
PoslPartner	može dobiti <0..M> glasi na <1..1>	Racun
Artikl	je naveden u <0..M> su tipa <1..1>	StavProdNaloga
Oprema	je rezervirana <0..M> se odnosi na <1..1>	ZauzećeOpreme
Ugovor	ima <0..M> pripada <1..1>	UgovObliSurad
OrgJedinica	prima po <0..M> glasni na <1..1>	Izdatnica
Zaposlenik	odobrava <0..M> je odobrena od <1..1>	Zahtjevnica
Artikl	je sastavni dio <0..M> jest tipa <1..1>	MatSastavnica
KontniPlan	je nadređen <0..M> je podređen <1..1>	KontniPlan
Proračun	ima <0..M> pripada <1..1>	PlanStav
PoslPartner	može imati <0..M> se odnosi na <1..1>	Ugovor

Korak 3: Izrada kataloga objekata podatkovnih modela.

Za odabrane modele podatka je potrebno izraditi abecedne kataloge entiteta (objekata) podatkovnih modela s indeksima od 1 do N/M, gdje je N/M ukupni broj entiteta modela podataka za visoka učilišta i za proizvodna poduzeća. Svakom entitetu se dodjeljuje identifikacijski broj, koji će predstavljati broj čvora u usmjerenom grafu (tablice 7.6. i 7.7.). Oznaka ishodišnog i odredišnog vrha (čvora) se u početnom prevođenju dodjeljuje entitetu po abecednom popisu objekata svakog podatkovnog modela (tako će na primjer broj jedan imati Akademski kalendar u podatkovnom modelu visokog učilišta, a u podatkovnom modelu proizvodnog poduzeća će oznaku 1 dobiti Artikel).

Kod formiranja tablica 7.6. i 7.7. potrebno je provesti i dodavanje virtualnih entiteta koji će predstavljati virtualne vrhove. Dodavanje virtualnih vrhova je potrebno jer matematički alat koji je korišten za razvoj algoritma ne podržava unarne veze – petlje – vrhova na usmjerenom grafu, kao niti istosmjerne višestruke veze dvaju vrhova. Sve parove također treba unijeti u odgovarajući radni list datoteke „priprema.xls“ kako bi se izjednačile oznake vrhova semantički sličnih parova objekata te kreirao skup svih potrebnih podataka za usporedbu modela pomoću algoritma temeljenog na teoriji grafova.

Tablica 7.6.: Katalog entiteta modela podataka podatkovnog modela za visoka učilišta

1.	AkademKalen
2.	AktivnPostupka
3.	Autori
4.	Cjenik
5.	Dvorane
6.	Institucija
7.	IshUcenja
8.	IshUcenjPredmeta
9.	ISHUcenjProg
10.	IspitniRok
11.	IspunjUvjeta
12.	IzborUZvanje
13.	KategRada
14.	KontniPlan
15.	MedjusobUvjet
16.	NositeljProg
17.	ObliciAktivn
18.	ObrazProfili
19.	ObvezeStud
20.	Oprema
21.	Placanje
22.	PlanAktivnosti

23.	PlanStav
24.	Postupak
25.	Predmet
26.	PrijavaIspita
27.	PriznStudPrava
28.	ProgStudija
29.	Projekt
30.	Proračun
31.	PutNal
32.	PutTrosk
33.	Racun
34.	RadAktivn
35.	RadMjesta
36.	RadNaProjektu
37.	Radovi
38.	Raspored
39.	StatusPostupka
40.	StatusPrijavIspita
41.	StavGlavKnjige
42.	StavPutNal
43.	StavRacuna
44.	StavRasporeda

45.	Student
46.	Studij
47.	StudObveze
48.	StudPrava
49.	TemaRada
50.	UpisneKvote
51.	UpisniList
52.	UpisPredmeta
53.	UpisStudenta
54.	Usluge
55.	Uvjeti
56.	VrstaProj
57.	XKontniPlan
58.	XPredmet
59.	Zahtjev
60.	ZaposlenikVU
61.	Zaposlenje
62.	ZauzeceOpreme
63.	ZnanPodrucje
64.	Zvanja

Tablica 7.7.: Katalog entiteta modela podataka podatkovnog modela za proizvodna poduzeća

1.	Artikl	23.	ProdNalog	45.	Zahtjevnica
2.	Cjenik	24.	Proračun	46.	Zaposlenik
3.	dodjelOvlas	25.	Racun	47.	Zaposlenje
4.	GlavPlanProiz	26.	RadKalendar	48.	ZauzeceOpreme
5.	GrupaProizv	27.	RadMjesta		
6.	Izdatnica	28.	RadNalog		
7.	KontniPlan	29.	StatusNaloga		
8.	MatSastavnica	30.	StavGlavKnjige		
9.	MogućeGrupe	31.	StavIzdat		
10.	Narudzba	32.	StavNarudz		
11.	ObliciSuradnje	33.	StavOtprem		
12.	Operacije	34.	StavPrim		
13.	Oprema	35.	StavProdNaloga		
14.	OrgJedinica	36.	StavRacuna		
15.	Otpremnica	37.	StavRadNaloga		
16.	Ovlastenja	38.	StavZahtjev		
17.	Placanje	39.	UgovObliSurad		
18.	PlanProizProg	40.	Ugovor		
19.	PlanStav	41.	XArtikl		
20.	Pogoni	42.	XKontniPlan		
21.	PoslPartner	43.	XOrgJedinica		
22.	Primka	44.	XZaposlenik		

Korak 4: Izrada kataloga tipova veza podatkovnih modela.

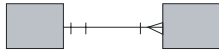

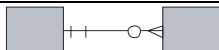
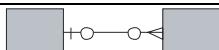
Za odabrane modele podataka treba izraditi katalog relevantnih tipova veza entiteta (objekata) podatkovnih modela. Svaki tip veze može predstavljati kombinaciju svojstava veze kao što su: tip povezivanja (primarni ili vanjski ključ), opcionalnost, učestalost i druga svojstva veze koja su relevantna. Svakom tipu veze se dodjeljuje brojčana oznaka koja će se kasnije koristiti kao težina luka (tablica 7.8.).

U podatkovnim modelima koji prikazuju osnovne koncepte ERP sustava su prema poslovnim pravilima korištene različite veze objekata. Te veze prikazuju kakvi su odnosi između objekata s obzirom na:

- povezivanje objekata s načinom sudjelovanja atributa jednog objekta u drugom sa svojstvom dijela primarnog ključa ili vanjskog ključa,
- povezivanje objekata s određenim ograničenjima u brojnosti veze,
- povezivanje objekata s obzirom na način učešća (opcionalno ili obvezno).

Na modelima se mogu pojaviti ukupno 4 tipa veza koji su prikazani u tablici 7.8. Svakom tipu veze ćemo dodijeliti brojčanu vrijednost koju ćemo kasnije koristiti kao težinu veze.

Tablica 7.8.: Moguće vrsta veza entiteta

Tip veze	Učestalost referenciranja objekta a u drugom objektu sa ili bez opcionalnosti (0 ili 1 naprema više)	Učestalost povezanosti s referenciranim objektom sa ili bez opcionalnosti (0 ili 1 naprema više)	Težina
	1..1	1..M	4
	0..1	1..M	3
	1..1	0..M	2
	0..1	1..M	1

Ovu tablicu je moguće dopunjavati i drugim mogućim kombinacijama koje nisu prisutne u primjeru, ali ju je isto tako moguće formirati i po drugim kriterijima koji bi se mogli smatrati težinom luka između dva entiteta predstavljena vrhovima u grafu.

Korak 5: Kreiranje liste lukova početnih grafova.

Svaki redak iz tablica 7.4. i 7.5. treba prevesti u oblik koji je prikladan za izradu usmjerenog grafa, odnosno treba formirati zapis u obliku uređenog para **[[x,y],z]**, pri čemu X – broj ishodišnog entiteta iz kojeg se preuzima identifikator, odabire se iz kataloga entiteta prvog modela podataka, u grafu će to biti ishodišni vrh luka; Y – broj odredišnog entiteta u kojem se preuzima identifikator od X, odabire iz kataloga entiteta drugog modela podataka, u grafu će to biti odredišni vrh luka; a Z predstavlja oznaku tipa veze, odabire se iz kataloga veza entiteta, u grafu će to biti težina luka koji ide iz X u Y (tablice 7.9. i 7.10).

Ishodišni vrh luka je entitet iz kojeg se preuzima (odnosno u kojem se referencira) ključni atribut i prenosi u drugi entitet kao vanjski ključ ili kao dio primarnog ključa. Odredišni vrh luka je entitet u kojem se preuzima ključni atribut kao vanjski ključ ili kao dio primarnog ključa. Luk je usmjereni brid koji je usmjeren od ishodišnog ka odredišnom vrhu, odnosno prikazuje smjer prijenosa atributa. Težina luka je određena kombinacijom tipa veze entiteta (skup mogućih vrijednosti težine luka je prikazan u tablici 7.8.).

Tablice 7.4. i 7.5. treba dopuniti četvrtim stupcem (prikazano u tablicama 7.9. i 7.10.) u kojem će svaki par entiteta i njihova veza biti zapisani u obliku koji je prikladan za izradu usmjerenog grafa: **[[x,y],z]**. Ovaj postupak se provodi u datoteci tabličnog kalkulatora “priprema.xls” na temelju tablica 7.4. do 7.8.

Tablica 7.9. Popis veza objekata podatkovnog modela za visoka učilišta sa zapisom lukova grafa $[[x,y],z]$

Ishodišni entitet	Veza	Odredišni entitet	Veza $[[x,y],z]$
Student	se može <0..M> se odnosi na <1..1>	UpisStudenta	$[[45,53],2]$
Predmet	se polaže <0..M> se odnosi na <1..1>	IspitniRok	$[[25,10],2]$
IspitniRok	vrijedi ako postoji <0..M> se odnosi na <1..1>	PrijavaIspita	$[[10,26],2]$
Student	pristupa ispitu <0..M> se odnosi na <1..1>	PrijavaIspita	$[[45,26],2]$
Predmet	se izvodi prema <0..M> obuhvaća <1..1>	StavRasporeda	$[[25,44],2]$
Predmet	imati preduvjet <0..M> se odnosi na <1..1>	MedjusobUvjet	$[[25,15],2]$
AkademKalen	definira vrijeme <0..M> je određen <1..1>	StavRasporeda	$[[1,44],2]$
Dvorane	definira prostorna ograničenja <0..M> je određen <1..1>	StavRasporeda	$[[5,44],2]$
Institucija	je primatelj <0..M> se odnosi na <1..1>	Racun	$[[6,33],2]$
Predmet	može biti izvor <0..M> može biti u području <0..1>	TemaRada	$[[25,49],1]$
Oprema	se koristi za izvedbu <0..M> koristi <1..1>	ZauzeceOpreme	$[[20,62],2]$
StavRasporeda	koristi <0..M> se odnosi na <1..1>	ZauzeceOpreme	$[[44,62],2]$
Racun	je temelj za <0..M> se provodi na temelju <1..1>	Placanje	$[[33,21],2]$
ZaposlenikVU	može biti mentor <0..M> je zadana od <1..1>	TemaRada	$[[60,49],2]$
Student	je autor <0..M> je izrađen od <1..1>	TemaRada	$[[45,49],2]$
Student	može biti primatelj <0..M> se odnosi na <0..1>	Racun	$[[45,33],1]$
ZaposlenikVU	sudjeluje u izvedbi <0..M> izvodi <1..M>	StavRasporeda	$[[60,44],2]$
ObliciAktivn	su odabrani u <0..M> se odnosi na <0..1>	StavRasporeda	$[[17,44],1]$
Studij	se odnose na <1..M> je ograničen <0..1>	UpisneKvote	$[[46,50],3]$
StudPrava	se mogu dodijeliti <0..M> jest tipa <0..1>	PriznStudPrava	$[[48,27],1]$
Zahtjev	pokreće otvaranje <0..M> je pokrenut na temelju <1..1>	Postupak	$[[59,24],2]$
AktivnPostupka	se obavljaju za rješavanje <0..M> je određen završetkom <1..1>	StatusPostupka	$[[2,39],2]$
ZaposlenikVU	ima <0..M> se odnosi na <1..1>	IzborUZvanje	$[[60,12],2]$
Student	predaje <0..M> je predao <1..1>	Zahtjev	$[[45,59],2]$
Student	može imati <0..M> se odnose na <1..1>	ObvezeStud	$[[45,19],2]$
ObrazProfili	su definirani za <0..M> rezultira <1..1>	Studij	$[[18,46],2]$
KontniPlan	definira <0..M> se knjiže prema <1..1>	StavGlavKnjige	$[[14,41],2]$
ZaposlenikVU	zadaje <0..M> je zadan od <1..1>	IspitniRok	$[[60,10],2]$
ZaposlenikVU	e nositelj <0..M> je prijavljen od <1..1>	Projekt	$[[60,29],2]$
ZaposlenikVU	evidentira sate za <0..M> se odnosi na <1..1>	RadNaProjektu	$[[60,36],2]$
VrstaProj	definira <0..M> jest tipa <1..1>	Projekt	$[[56,29],2]$
ZaposlenikVU	je autor <0..M> je napisan od <1..1>	Autori	$[[60,3],2]$
Radovi	ima <0..M> je vezan uz <1..1>	Autori	$[[37,3],2]$
KategRada	opisuje vrstu <0..M> jest tipa <1..1>	Radovi	$[[13,37],2]$
Studij	ima <0..M> pripada <1..1>	ISHUcenjProg	$[[46,9],2]$
IshUcenja	su vezani <0..M> jest tipa <1..1>	ISHUcenjProg	$[[7,9],2]$
IshUcenja	pripada <0..M> ima <1..1>	IshUcenjPredmeta	$[[7,8],2]$
Institucija	može biti <0..M> jest <1..1>	NositeljProg	$[[6,16],2]$
Studij	može imati <0..M> se odnosi na <1..1>	NositeljProg	$[[46,16],2]$
Raspored	može imati <0..M> pripada <1..1>	StavRasporeda	$[[38,44],2]$

Studij	ima svoj <0..M> pripada <1..1>	Raspored	[[46,38],2]
AkademKalen	opisuje <0..M> se provodi prema <1..1>	PlanAktivnosti	[[1,22],2]
ZaposlenikVU	može imati <0..M> se odnosi na <1..1>	Zaposlenje	[[60,61],2]
RadMjesta	opisuje <0..M> se odnosi na <1..1>	Zaposlenje	[[35,61],2]
ZaposlenikVU	ima <0..M> se odnosi na <1..1>	PlanAktivnosti	[[60,22],2]
Student	može upisati <0..M> se odnosi na <1..1>	UpisniList	[[45,51],2]
UpisniList	ima <0..M> se odnose na <1..1>	UpisPredmeta	[[51,52],2]
Predmet	se upisuje <0..M> se odnosi na <1..1>	UpisPredmeta	[[25,52],2]
AkademKalen	određuje <0..M> pripada <1..1>	IspitniRok	[[1,10],2]
KontniPlan	određuje <0..M> su tipa <1..1>	PlanStav	[[14,23],2]
Predmet	može imati <0..M> se odnosi na <0..1>	PlanAktivnosti	[[25,22],1]
Postupak	može imati <0..M> se odnosi na <1..1>	StatusPostupka	[[24,39],2]
StudObveze	se mogu dodijeliti <0..M> su tiao <1..1>	ObvezeStud	[[47,19],2]
Zvanja	mogu biti dodijeljena <0..M> se odnosi na <1..1>	IzborUZvanje	[[64,12],2]
Uvjeti	su ocijenjeni <0..M> su za <1..1>	IspunjUvjeta	[[55,11],2]
Student	može imati <0..M> se odnosi na <1..1>	PriznStudPrava	[[45,27],2]
IzborUZvanje	je referenciran u <0..M> se odnosi na <1..1>	IspunjUvjeta	[[12,11],2]
ObliciAktivn	su navedeni u <0..M> jest tipa <1..1>	PlanAktivnosti	[[17,22],2]
Racun	je temelj za <0..M> se odnosi na <0..1>	StavGlavKnjige	[[33,41],1]
Studij	je odabran <0..M> se odnosi na <1..1>	UpisStudenta	[[46,53],2]
Projekt	ima aktivnosti <0..M> se odnosi na <1..1>	RadNaProjektu	[[29,36],2]
ZnanPodrucje	klasificira <0..M> pripada <1..1>	Radovi	[[63,37],2]
ZnanPodrucje	klasificira <0..M> pripada <1..1>	Projekt	[[63,29],2]
Predmet	Ima <0..M> se odnose na <1..1>	IshUcenjPredmeta	[[25,8],2]
Racun	ima <0..M> pripadaju <1..1>	StavRacuna	[[33,43],2]
AkademKalen	je referenciran u <0..M> se odnose na <1..1>	UpisneKvote	[[1,50],2]
Usluge	ima <0..M> se odnosi na <1..1>	Cjenik	[[54,4],2]
Usluge	se koristi za <0..M> jest tipa <1..1>	StavRacuna	[[54,43],2]
RadAktivn	su navedene <0..M> su tipa <1..1>	RadNaProjektu	[[34,36],2]
PrijavIspita	ima <0..M> opisuje <1..1>	StatusPrijavIspita	[[26,40],2]
ZaposlenikVU	unos <0..M> je unesen od <1..1>	StatusPrijavIspita	[[60,40],2]
XPredmet	može biti preduvjet <0..M> se odnosi <1..1>	MedjusobUvjet	[[58,15],2]
XKontniPlan	je nadređen <0..M> je tipa <1..1>	KontniPlan	[[57,14],2]
Predmet	ima statusa u programu studija <0..M> se odnosi na <1..1>	ProgStudija	[[25,28],2]
PutNal	je kreiran za <1..M> može imati <0..1>	ZaposlenikVU	[[31,60],3]
PutNal	može imati <0..M> pripada <1..1>	StavPutNal	[[31,42],2]
PutTrosk	opisuje <0..M> jest tipa <1..1>	StavPutNal	[[32,42],2]
Proračun	ima <0..M> pripadaju <1..1>	PlanStav	[[30,23],2]

Tablica 7.10.: Popis veza objekata podatkovnog modela za proizvodna poduzeća sa zapisom lukova grafa $[[x,y],z]$

Ishodišni entitet	Veza	Odredišni entitet	Veza $[[x,y],z]$
Zaposlenik	je izdao <0..M> je kreirana od <1..1>	Zahtjevnica	$[[46,45],2]$
Zahtjevnica	može biti temelj za <0..M> se temelji na <0..1>	Narudžba	$[[45,10],1]$
PoslPartner	je naručio artikle u <0..M> se odnosi na <1..1>	ProdNalog	$[[21,23],2]$
Artikl	se sastoji od <0..M> opisuje <1..1>	MatSastavnica	$[[1,8],2]$
PoslPartner	je isporučio robu prema <0..M> potvrđuje isporuku od <1..1>	Primka	$[[21,22],2]$
PoslPartner	prima robu <0..M> glasi na <1..1>	Otpremnica	$[[21,15],2]$
StatusNaloga	opisuje <0..M> ima <1..1>	RadNalog	$[[29,28],2]$
Ovlastjenja	moгу biti didijeljena <0..M> su tipa <1..1>	dodjelOvlas	$[[16,3],2]$
Zaposlenik	može imati <0..M> se odnosi na <1..1>	dodjelOvlas	$[[46,3],2]$
RadMjesta	određuje <0..M> je za <1..1>	Zaposlenje	$[[27,47],2]$
Zaposlenik	ima <0..M> se odnosi na <1..1>	Zaposlenje	$[[46,47],2]$
RadNalog	ima <0..M> pripada <1..1>	StavRadNaloga	$[[28,37],2]$
Racun	ima <0..M> pripada <1..1>	StavRacuna	$[[25,36],2]$
Zahtjevnica	ima <0..M> pripada <1..1>	StavZahtjev	$[[45,38],2]$
ObliciSuradnje	je ugovoren u <0..M> je određen <1..1>	UgovObliSurad	$[[11,39],2]$
KontniPlan	definira <0..M> se knjiži prema <1..1>	StavGlavKnjige	$[[7,30],2]$
RadKalendar	se koristi za <0..M> je ograničen <1..1>	StavRadNaloga	$[[26,37],2]$
Artikl	se zaprima <0..M> obuhvaća <1..1>	StavPrim	$[[1,34],2]$
Primka	može imati <0..M> pripada <1..1>	StavPrim	$[[22,34],2]$
Artikl	je naveden u <0..M> se odnosi na <1..1>	StavOtprem	$[[1,33],2]$
Artikl	je naveden u <0..M> se odnosi na <1..1>	StavIzdat	$[[1,31],2]$
Narudžba	ima <0..M> pripada <1..1>	StavNarudz	$[[10,32],2]$
Artikl	je naveden u <0..M> jest tipa <1..1>	StavNarudz	$[[1,32],2]$
Artikl	je naveden u <0..M> definira cijenu <1..1>	Cjenik	$[[1,2],2]$
Racun	se knjiži <1..M> se odnosi na <0..1>	StavGlavKnjige	$[[25,30],3]$
Zaposlenik	je izvršitelj <0..M> postupa prema <1..1>	StavRadNaloga	$[[46,37],2]$
ProdNalog	ima <0..M> pripada <1..1>	StavProdNaloga	$[[23,35],2]$
KontniPlan	definira <0..M> se odnosi na <1..1>	PlanStav	$[[7,19],2]$
PoslPartner	prima <0..M> glasi na <1..1>	Narudžba	$[[21,10],2]$
Artikl	se planira proizvesti u <0..M> se odnosi na <1..1>	GlavPlanProiz	$[[1,4],2]$
Artikl	pripada <0..M> se odnosi na <1..1>	GrupaProizv	$[[1,5],2]$
MogućeGrupe	definiraju <0..M> se odnosi na <1..1>	GrupaProizv	$[[9,5],2]$
MogućeGrupe	se navode u <0..M> se odnosi na <1..1>	PlanProizProg	$[[9,18],2]$
RadKalendar	opisuje <0..M> se odnosi na <1..1>	PlanProizProg	$[[26,18],2]$
Operacije	opisuju <0..M> obuhvaća <1..1>	GlavPlanProiz	$[[12,4],2]$
StavRadNaloga	koristi <0..M> se odnosi na <1..1>	ZauzećeOpreme	$[[37,48],2]$
RadKalendar	opisuje <0..M> se provodi prema <1..1>	GlavPlanProiz	$[[26,4],2]$
Artikl	je naveden u <0..M> su tipa <1..1>	StavRacuna	$[[1,36],2]$
OrgJedinica	je primatelj <0..M> glasi na <1..1>	Primka	$[[14,22],2]$
Primka	se knjiži <0..M> se odnosi na <1..1>	StavGlavKnjige	$[[22,30],2]$
OrgJedinica	otprema pomoću <0..M> je izdana od <1..1>	Otpremnica	$[[14,15],2]$

OrgJedinica	izdaje <0..M> je izdana <1..1>	Izdatnica	[[14,6],2]
Izdatnica	se knjižina <0..M> se odnosi na <1..1>	StavGlavKnjige	[[6,30],2]
Racun	je temelj za <0..M> se odnosi na <1..1>	Placanje	[[25,17],2]
Artikl	je naveden u <0..M> se odnosi na <1..1>	StavRadNaloga	[[1,37],2]
Artikl	je naveden u <0..M> je tipa <1..1>	StavZahtjev	[[1,38],2]
Operacije	su navedene u <0..M> su određene <1..1>	StavRadNaloga	[[12,37],2]
Pogoni	je neveden u <0..M> se izvodi u <1..1>	StavRadNaloga	[[20,37],2]
Izdatnica	ima <0..M> pripada <1..1>	StavIzdat	[[6,31],2]
Otpremnica	ima <0..M> pripada <1..1>	StavOtprem	[[15,33],2]
PoslPartner	može dobiti <0..M> glasi na <1..1>	Racun	[[21,25],2]
Artikl	je naveden u <0..M> su tipa <1..1>	StavProdNaloga	[[1,35],2]
Oprema	je rezervara <0..M> se odnosi na <1..1>	ZauzeceOpreme	[[13,48],2]
XArtikl	je sastavni dio <0..M> jest tipa <1..1>	MatSastavnica	[[41,8],2]
XKontniPlan	je nadređen <0..M> je podređen <1..1>	KontniPlan	[[42,7],2]
XZaposlenik	odobrava <0..M> je odobrena od <1..1>	Zahtjevnica	[[44,45],2]
XOrgJedinica	prima po <0..M> glasni na <1..1>	Izdatnica	[[43,6],2]
Ugovor	ima <0..M> pripada <1..1>	UgovObliSurad	[[40,39],2]
Proračun	ima <0..M> pripada <1..1>	PlanStav	[[24,19],2]
PoslPartner	može imati <0..M> se odnosi na <1..1>	Ugovor	[[21,40],2]

Korak 6: Identifikacija parova semantički sličnih objekata.

Kreirati dvostupčanu tablicu odabranih entiteta koja u svakom retku obuhvaća par entiteta prvog i drugog podatkovnog modela za koje se pretpostavlja da su semantički slični. Redoslijed redaka nije važan.

Ukupno je pronađeno dva puta po 27 semantički sličnih entiteta od kojih su 2 para virtualnih vrhova: XPredmet i XKontniPlan koji su semantički slični XArtikl i XKontniPlan.

U prvom stupcu je entitet modela podataka za VU, a drugom stupcu semantički sličan entitet iz podatkovnog modela za proizvodno poduzeće. U trećem i četvrtom stupcu su brojevi entiteta iz kataloga entiteta, respektivno. Broj entiteta je ujedno i broj vrha na usmjerenom grafu. Da bi se osigurala usporedivost usmjerenih grafova dobivenih iz podatkovnih modela, potrebno je permutirati izvorne matrice susjedstva usmjerenih grafova. Prilikom permutacije redaka i stupaca će se ujedno provesti i redukcija matrice na samo one retke i stupce koji imaju semantički sličnog entiteta-para. Zato je u krajnje desnom stupcu novi broj vrha, odnosno položaj vrha u listi odabranih vrhova, koji će ujedno biti i novi broj vrha u podmatrici susjedstva.

Tablica 7.11.: Odabir semantički sličnih entiteta, njihove oznake i novi položaj u matrici susjedstva

Odabir entiteta iz 1. modela	Odabir entiteta iz 2. modela	Početni broj entiteta 1. modela	Početni broj entiteta 2. modela	Novi broj entiteta /položaj vrha u listi podmatrici susjedstva
Student	PoslPartner	45	21	1
ZaposlenikVU	Zaposlenik	60	46	2
Predmet	Artikl	25	1	3
KontniPlan	KontniPlan	14	7	4
Racun	Racun	33	25	5
StavGlavKnjige	StavGlavKnjige	41	30	6
Placanje	Placanje	21	17	7
StavRacuna	StavRacuna	43	36	8
StavRasporeda	StavRadNaloga	44	37	9
ZauzeceOpreme	ZauzeceOpreme	62	48	10
PlanStav	PlanStav	23	19	11
MedjusobUvjet	MatSastavnica	15	8	12
ObliciAktivn	Operacije	17	12	13
AkademKalen	RadKalendar	1	26	14
Raspored	RadNalog	38	28	15
Dvorane	Pogoni	5	20	16
PlanAktivnosti	GlavPlanProiz	22	4	17
UpisneKvote	PlanProizProg	50	18	18
Studij	MogućeGrupe	46	9	19
Oprema	Oprema	20	13	20
Proračun	Proračun	30	24	21
UpisniList	ProdNalog	51	23	22
UpisPredmeta	StavProdNaloga	52	35	23
Zaposlenje	Zaposlenje	61	47	24
RadMjesta	RadMjesta	35	27	25
Cjenik	Cjenik	4	2	26
ProgStudija	GrupaProizv	28	5	27
XPredmet	XArtikl	58	41	28
XKontniPlan	XKontniPlan	57	42	29

Provedba ovih koraka prevođenja grafičkog modela podataka u usmjereni graf je realizirana u datoteci „priprema.xls“, pripremljenoj u tabličnom kalkulatoru. Ulazni podaci za datoteku tabličnog kalkulatora su identificirane veze među entitetima. Ovisno o alatu za modeliranje podataka, formati izvještaja o vezama entiteta podatkovnih modela mogu varirati. Za korištenje datoteke „priprema.xls“ popisi veza moraju imati isti format kao i podaci u tablicama 7.4., do 7.11.

Tablica 7.12.: Podaci iz „priprema.xls“ za datoteku „usporedba.wxm“

Skup vrhova i lukova iz podatkovnog modela za visoka učilišta
[[45,53],2],[[25,10],2],[[10,26],2],[[45,26],2],[[25,44],2],[[25,15],2],[[1,44],2],[[5,44],2],[[6,33],2],[[25,49],1],[[20,62],2],[[44,62],2],[[33,21],2],[[60,49],2],[[45,49],2],[[45,33],1],[[60,44],2],[[17,44],1],[[46,50],3],[[48,27],1],[[59,24],2],[[2,39],2],[[60,12],2],[[45,59],2],[[45,19],2],[[18,46],2],[[14,41],2],[[60,10],2],[[60,29],2],[[60,36],2],[[56,29],2],[[60,3],2],[[37,3],2],[[13,37],2],[[46,9],2],[[7,9],2],[[7,8],2],[[6,16],2],[[46,16],2],[[38,44],2],[[46,38],2],[[1,22],2],[[60,61],2],[[35,61],2],[[60,22],2],[[45,51],2],[[51,52],2],[[25,52],2],[[1,10],2],[[14,23],2],[[25,22],1],[[24,39],2],[[47,19],2],[[64,12],2],[[55,11],2],[[45,27],2],[[12,11],2],[[17,22],2],[[33,41],1],[[46,53],2],[[29,36],2],[[63,37],2],[[63,29],2],[[25,8],2],[[33,43],2],[[1,50],2],[[54,4],2],[[54,43],2],[[34,36],2],[[26,40],2],[[60,40],2],[[58,15],2],[[57,14],2],[[25,28],2],[[31,60],3],[[31,42],2],[[32,42],2],[[30,23],2]
Skup vrhova i lukova iz podatkovnog modela za proizvodna poduzeća
[[46,45],2],[[45,10],1],[[21,23],2],[[1,8],2],[[21,22],2],[[21,15],2],[[29,28],2],[[16,3],2],[[46,3],2],[[27,47],2],[[46,47],2],[[28,37],2],[[25,36],2],[[45,38],2],[[11,39],2],[[7,30],2],[[26,37],2],[[1,34],2],[[22,34],2],[[1,33],2],[[1,31],2],[[10,32],2],[[1,32],2],[[1,2],2],[[25,30],3],[[46,37],2],[[23,35],2],[[7,19],2],[[21,10],2],[[1,4],2],[[1,5],2],[[9,5],2],[[9,18],2],[[26,18],2],[[12,4],2],[[37,48],2],[[26,4],2],[[1,36],2],[[14,22],2],[[22,30],2],[[14,15],2],[[14,6],2],[[6,30],2],[[25,17],2],[[1,37],2],[[1,38],2],[[12,37],2],[[20,37],2],[[6,31],2],[[15,33],2],[[21,25],2],[[1,35],2],[[13,48],2],[[41,8],2],[[42,7],2],[[44,45],2],[[43,6],2],[[40,39],2],[[24,19],2],[[21,40],2]
Popis vrhova za permutaciju HEI vrhova
[45,60,25,14,33,41,21,43,44,62,23,15,17,1,38,5,22,50,46,20,30,51,52,61,35,4,28,58,57]
Popis vrhova za permutaciju PRO vrhova
[21,46,1,7,25,30,17,36,37,48,19,8,12,26,28,20,4,18,9,13,24,23,35,47,27,2,5,41,42]
Skup naziva vrhova iz podatkovnog modela za visoka učilišta
[AkademKalen,AktivnPostupka,Autori,Cjenik,Dvorane,Institucija,IshUcenja,IshUcenjPredmeta,ISHUcenjProg,IspitniRok,IspunjUvjeta,IzborUZvanje,KategRada,KontniPlan,MedjusobUvjet,NositeljProg,ObliciAktivn,ObrazProfili,ObvezeStud,Oprema,Placanje,PlanAktivnosti,PlanStav,Postupak,Predmet,PrijavaIspita,PriznStudPrava,ProgStudija,Projekt,Proračun,PutNal,PutTrosk,Racun,RadAktivn,RadMjesta,RadNaProjektu,Radovi,Raspored,StatusPostupka,StatusPrijavaIspita,StavGlavKnjige,StavPutNal,StavRacuna,StavRasporeda,Student,Studij,StudObveze,StudPrava,TemaRada,UpisneKvote,UpisniList,UpisPredmeta,UpisStudenta,Usluge,Uvjeti,VrstaProj,XKontniPlan,XPredmet,Zahtjev,ZaposlenikVU,Zaposlenje,ZauzeceOpreme,ZnanPodrucje,Zvanja]
Skup naziva vrhova iz podatkovnog modela za proizvodna poduzeća
[Artikl,Cjenik,dodjelOvlas,GlavPlanProiz,GrupaProizv,Izdatnica,KontniPlan,MatSastavnica,MogućeGrupe,Narudzba,ObliciSuradnje,Operacije,Oprema,OrgJedinica,Otpremnica,Ovlastenja,Placanje,PlanProizProg,PlanStav,Pogoni,PoslPartner,Primka,ProdNalog,Proračun,Racun,RadKalendar,RadMjesta,RadNalog,StatusNaloga,StavGlavKnjige,StavIzdat,StavNarudz,StavOtprem,StavPrim,StavProdNaloga,StavRacuna,StavRadNaloga,StavZahtjev,UgovObliSurad,Ugovor,XArtikl,XKontniPlan,XOrgJedinica,XZaposlenik,Zahtjevnica,Zaposlenik,Zaposlenje,ZauzeceOpreme]
Popis težina veza
[veza_tipa_0..M0..1,veza_tipa_0..M1..1,veza_tipa_1..M0..1,veza_tipa_1..M1..1]

Podaci iz tablice 7.12. se unose u datoteku „usporedba.wxm“ te se nad njima provodi usporedba.

7.4.2.2. Primjena algoritma usporedbe grafova

Skupovi vrhova i lukova su ulazni podaci za algoritam određivanja strukturne sličnosti modela podataka. Druga faza usporedbe se sastoji od 8 koraka, koji su detaljno opisani i provedeni u nastavku. U nastavku je za svaki korak algoritma dan opis i skup naredbi u programskom alatu Wxmaxima. Svi ulazni podaci koji su potrebni za provedbu algoritma se dobivaju iz datoteke „priprema.xls“.

Korak 7: Kreiranje početnih grafova.

Provesti postupak prevođenja grafičkih modela u usmjerene grafove. Iz popisa veza u formatu $[[X,Y],Z]$ kreirati usmjerene težinske grafove: graf 1 koji prikazuje vrhove i lukove izvedene iz veza entiteta prvog modela podataka i graf 2 koji prikazuje vrhove i lukove izvedene iz veza entiteta drugog modela podataka.

Prevođenje grafičkog modela u usmjereni graf se provodi tako da se iz popisa veza u formatu $[[X,Y],Z]$ kreiraju usmjereni težinski grafovi: graf 1 koji prikazuje vrhove i lukove izvedene iz veza entiteta prvog modela podataka i graf 2 koji prikazuje vrhove i lukove izvedene iz veza entiteta drugog modela podataka.

Najprije se iz tablice 7.12. unosi lista veza u elemente lukovi₁²² i lukovi₂²³. Zatim se unosi lista naziva vrhova iz podatkovnih modela: nazivi_vrhova₁ i nazivi_vrhova₂. Nakon toga se kreiraju liste vrhova vrhovi₁ i vrhovi₂ za svaki model s obzirom na ukupni broj elemenata modela, pomoću odgovarajuće naredbe prikazane u nastavku.

```
lukovi_1:[  
[[45,53],2],[[25,10],2],[[10,26],2],[[45,26],2],[[25,44],2],[[25,15],2],[[1,44],2],[[5,44],2],[[6,33],2],[[25,49],  
1],[[20,62],2],[[44,62],2],[[33,21],2],[[60,49],2],[[45,49],2],[[45,33],1],[[60,44],2],[[17,44],1],[[46,50],3],[[  
48,27],1],[[59,24],2],[[2,39],2],[[60,12],2],[[45,59],2],[[45,19],2],[[18,46],2],[[14,41],2],[[60,10],2],[[60,29],  
2],[[60,36],2],[[56,29],2],[[60,3],2],[[37,3],2],[[13,37],2],[[46,9],2],[[7,9],2],[[7,8],2],[[6,16],2],[[46,16],2],[  
38,44],2],[[46,38],2],[[1,22],2],[[60,61],2],[[35,61],2],[[60,22],2],[[45,51],2],[[51,52],2],[[25,52],2],[[1,10],  
2],[[14,23],2],[[25,22],1],[[24,39],2],[[47,19],2],[[64,12],2],[[55,11],2],[[45,27],2],[[12,11],2],[[17,22],2],[  
33,41],1],[[46,53],2],[[29,36],2],[[63,37],2],[[63,29],2],[[25,8],2],[[33,43],2],[[1,50],2],[[54,4],2],[[54,43],2],  
[34,36],2],[[26,40],2],[[60,40],2],[[58,15],2],[[57,14],2],[[25,28],2],[[31,60],3],[[31,42],2],[[32,42],2],[[30,  
23],2]];
```

```
lukovi_2:[  
[[46,45],2],[[45,10],1],[[21,23],2],[[1,8],2],[[21,22],2],[[21,15],2],[[29,28],2],[[16,3],2],[[46,3],2],[[27,47],2],  
[46,47],2],[[28,37],2],[[25,36],2],[[45,38],2],[[11,39],2],[[7,30],2],[[26,37],2],[[1,34],2],[[22,34],2],[[1,33
```

²² Indeks 1 će imati elementi modela podataka za visoka učilišta

²³ Indeks 2 će imati elementi modela podataka za proizvodna poduzeća

```
],2],[[1,31],2],[[10,32],2],[[1,32],2],[[1,2],2],[[25,30],3],[[46,37],2],[[23,35],2],[[7,19],2],[[21,10],2],[[1,4],2],
[[1,5],2],[[9,5],2],[[9,18],2],[[26,18],2],[[12,4],2],[[37,48],2],[[26,4],2],[[1,36],2],[[14,22],2],[[22,30],2],[[1
4,15],2],[[14,6],2],[[6,30],2],[[25,17],2],[[1,37],2],[[1,38],2],[[12,37],2],[[20,37],2],[[6,31],2],[[15,33],2],[[2
1,25],2],[[1,35],2],[[13,48],2],[[41,8],2],[[42,7],2],[[44,45],2],[[43,6],2],[[40,39],2],[[24,19],2],[[21,40],2]];
```

```
nazivi_vrhova_1:[
AkademKalen,AktivnPostupka,Autori,Cjenik,Dvorane,Institucija,IshUcenja,IshUcenjPredmeta,ISHUcenjPro
g,IspitniRok,IspunjUvjeta,IzborUZvanje,KategRada,KontniPlan,MedjusobUvjet,NositeljProg,ObliciAktivn,O
brazProfili,ObvezeStud,Oprema,Placanje,PlanAktivnosti,PlanStav,Postupak,Predmet,PrijavaIspita,PriznStu
dPrava,ProgStudija,Projekt,Proračun,PutNal,PutTrosk,Racun,RadAktivn,RadMjesta,RadNaProjektu,Radovi,
Raspored,StatusPostupka,StatusPrijavaIspita,StavGlavKnjige,StavPutNal,StavRacuna,StavRasporeda,Studen
t,Studij,StudObveze,StudPrava,TemaRada,UpisneKvote,UpisniList,UpisPredmeta,UpisStudenta,Usluge,Uvje
ti,VrstaProj,XKontniPlan,XPredmet,Zahtjev,ZaposlenikVU,Zaposlenje,ZauzeceOpreme,ZnanPodrucje,Zvanj
a];
```

```
nazivi_vrhova_2:[
Artikl,Cjenik,dodjelOvlas,GlavPlanProiz,GrupaProizv,Izdatnica,KontniPlan,MatSastavnica,MogućeGrupe,Na
rudzba,ObliciSuradnje,Operacije,Oprema,OrgJedinica,Otpremnica,Ovlastenja,Placanje,PlanProizProg,PlanS
tav,Pogoni,PoslPartner,Primka,ProdNalog,Proračun,Racun,RadKalendar,RadMjesta,RadNalog,StatusNalog
a,StavGlavKnjige,StavIzdat,StavNarudz,StavOtprem,StavPrim,StavProdNaloga,StavRacuna,StavRadNaloga,
StavZahtjev,UgovObliSurad,Ugovor,XArtikl,XKontniPlan,XOrgJedinica,XZaposlenik,Zahtjevnica,Zaposlenik,
Zaposlenje,ZauzeceOpreme];
```

```
vrhovi_1: makelist(i,i,1,length(nazivi_vrhova_1));
```

```
vrhovi_2: makelist(i,i,1,length(nazivi_vrhova_2));
```

Iz lista vrhova i lukova u alatu se generiraju odgovarajući usmjereni grafovi.

```
graf_1: create_graph(vrhovi_1,lukovi_1,directed=true);
```

```
graf_2: create_graph(vrhovi_2,lukovi_2,directed=true);
```

Korak 8: Izvedba matrica susjedstva iz početnih grafova.

Iz grafova se generiraju težinske kvadratne matrice susjedstva kojima se veze između objekata prikazuju susjednošću vrhova s težinom koja opisuje tip veze. Funkcija za generiranje težinske matrice susjedstva je kreirana kao funkcija pod nazivom „matrica_grafa(n,veze)“ iz razloga što postojeće naredbe alata „wxmaxima“ izvorno ne obuhvaćaju ovu potrebnu funkciju.

```
matrica_grafa(n,veze):=block([m],m:diagmatrix(n,0),
for a:1 thru length(veze) do
(m[veze[a][1][1],veze[a][1][2]]:veze[a][2]),m)$
```

```
mat_1: matrica_grafa (length(vrhovi_1), lukovi_1);
```

```
mat_2: matrica_grafa (length(vrhovi_2), lukovi_2);
```

Korak 9: Kreiranje lista odabranih vrhova za uparivanje vrhova grafova.

Prema tablici odabranih semantički sličnih entiteta treba kreirati liste odabranih vrhova po kojima će se formirati podmatrice susjedstva. Za svaki entitet iz prvog stupca treba pronaći njegovu oznaku iz kataloga entiteta prvog modela podataka, a zatim staviti broj u listu odabranih vrhova 1. Zatim za svaki entitet iz drugog stupca treba pronaći njegovu oznaku iz kataloga entiteta drugog modela podataka a zatim staviti broj u listu odabranih vrhova 2.

Traženje zajedničkih elemenata lista lukova provodi se traženjem presjeka elemenata dvaju skupova p1 (koja predstavlja skup lukova iz liste lukovi_1) i p2 (koja predstavlja skup lukova iz liste lukovi_2). Ovaj korak također zahtjeva pripremnu radnju, jer vrhovi podatkovnih modela nemaju iste oznake za semantički slične objekte-parove. Npr. Objekt Student u listi vrhovi_1 ima oznaku 44, dok njegov semantički sličan par Poslovni partner u listi vrhovi_2 ima oznaku 21. Ako želimo naći iste veze koje imaju prema ostalim objektima, moramo izjednačiti oznake svih semantički sličnih vrhova. Ostale vrhove, dakle one koji nemaju svog semantički sličnog para, ne razmatramo dalje jer usporedba takvih objekata nema smisla.

Izjednačavanje oznaka vrhova odabranih objekata-parova se u algoritmu radi pomoću lista odabranih vrhova za svaki skup lukova i vrhova. Liste odabranih vrhova se formiraju u „priprema.xls“ odabirom parova semantički sličnih objekata. Lista odabranih vrhova se unosi tako da se unese redoslijed oznaka vrhova po redu kako ih se želi permutirati u matrici susjedstva. Unos liste odabranih vrhova prema semantički sličnim parovima se izvodi pomoću naredbe za unos liste odabranih parova (skraćeno lov):

```
lov_1:[ 45,60,25,14,33,41,21,43,44,62,23,15,17,1,38,5,22,50,46,20,30,51,52,61,35,4,28,58,57]$  
lov_2:[ 21,46,1,7,25,30,17,36,37,48,19,8,12,26,28,20,4,18,9,13,24,23,35,47,27,2,5,41,42]$
```

Korak 10: Izdvajanje podmatrica susjedstva iz matrica susjedstva početnih grafova temeljem lista odabranih vrhova.

Na temelju lista odabranih vrhova, iz početnih matrica susjedstva izdvajamo kvadratne matrice permutacije, odnosno podmatrice susjedstva u kojima su samo vrhovi i njihovi lukovi koji imaju semantički sličan objekt u drugom modelu, a eliminiramo retke i stupce

Matrica susjedstva nakon provedene permutacije redaka i stupaca za graf proizvodno poduzeće izgleda ovako:

[illegible]

Korak 11: Kreiranje liste lukova vrhova iz podmatrica susjedstva.

Iz permutiranih kvadratnih matrica susjedstva 1 i 2 izdvojiti sve lukove grafa 1 i grafa 2 u obliku $[[X,Y],Z]$ u podskupove lukova 1 i 2. Kreiranje novih lista lukova iz podmatrica semantički sličnih objekata sa izjednačenim oznakama vrhova se provodi tako da se iz permutiranih kvadratnih matrica susjedstva 1 i 2 izdvoje svi lukovi grafa 1 i grafa 2 u obliku $[[X,Y],Z]$ u podskupove lukova 1 i 2. Zbog permutacije redaka i stupaca isti broj vrha će imati entiteti podatkovnih modela koji su semantički slični. Kreiranje liste novih oznaka vrhova i liste veza iz podmatrica (lukova podgrafova koji obuhvaćaju samo parove semantički sličnih objekata) s novim oznakama vrhova koje odgovaraju novom poretku prema listama odabranih vrhova, izvodi se pomoću sljedeće naredbe:

```
renum_lov_1:makelist(i,i,1,length(lov_1));
renum_lov_2:makelist(i,i,1,length(lov_2));
```

```
daj_veze(matrica):=block([veze],
veze:[],
for a:1 thru matrix_size(matrica)[1] do
  for b:1 thru matrix_size(matrica)[1] do
    (if matrica[a,b]#0 then veze:append(veze,[[a,b],matrica[a,b]])),veze)$
vezepodmat_1:daj_veze(podmat_1);
vezepodmat_2:daj_veze(podmat_2);
```

Zbog permutacije redaka i stupaca, isti broj vrha će imati entiteti podatkovnih modela koji su semantički slični. Ovim korakom je omogućena usporedba elemenata matrica, a usporedba se provodi pomoću presjeka skupova.

Korak 12: Određivanje presjeka lukova.

U podskupovima lukova su zapisane veze između semantički sličnih objekata s uparenim broječanim oznakama vrhova. Među elementima podskupova lukova treba pronaći presjek. Time se utvrđuju lukovi istih težina između vrhova s istim oznakama.

Zbog toga što funkcija „presjek“ radi nad skupovima, liste lukova je potrebno pretvoriti u skupove lukova sljedećim naredbama:

```
skup_1:setify(vezepodmat_1);
skup_2:setify(vezepodmat_2);
```

Zatim se traži presjek skupova 1 i 2:

```
presjekLukovaDigrafova:intersection (skup_1, skup_2);
lukovi_zaj:listify(presjekLukovaDigrafova);
```

Ovaj korak je ključan za pronalaženje strukturnih sličnosti dvaju modela podataka, jer svaku vezu objekata jednog modela uspoređuje s vezama objekata drugog modela. Usporedba se provodi pomoću operacije presjeka dvaju skupova čiji su elementi lukovi usmjerenih grafova.

Korak 13: Određivanje presjeka vrhova.

Iz presjeka lukova treba eliminirati vrhove koji nemaju niti jedan ulazni ili izlazni luk. Ti vrhovi predstavljaju entitete za koje je pretpostavljena semantička sličnost, ali nije utvrđena strukturna sličnost analizom veza. Preostali vrhovi su zajednički, odnosno to predstavljaju semantički sličan objekt s bar jednom strukturno sličnom vezom prema nekom drugom objektu na oba uspoređena modela.

Redukcija podskupa vrhova eliminacijom vrhova bez bar jednog ulaznog ili izlaznog luka se izvršava sljedećom naredbom:

```
presjek_vrhova(x):=listify(setify(flatten(map(lambda([y],y[1]),listify(x)))))$  
vrhovi_zaj:presjek_vrhova(presjekLukovaDigrafova);
```

U ovom koraku se analizira presjek skupova lukova i kreira lista vrhova koji se pojavljuju u presjeku skupova lukova ili kao ulazni ili kao izlazni vrh. Ovaj korak je važan jer se u presjeku skupova lukova ne moraju nalaziti svi početni vrhovi grafova. Kako na zajedničkom podgrafu početnih grafova ne želimo imati izolirane vrhove, potrebno je eliminirati sve vrhove iz početnih grafova koji u zajedničkom skupu lukova nemaju bar jedno pojavljivanje (kao ishodišni ili odredišni vrh).

Korak 14: Kreiranje grafa iz presjeka vrhova i presjeka lukova.

Kreiranje zajedničkog podgraфа na temelju elemenata iz presjeka lukova (lukovi_zaj) i presjeka vrhova (vrhovi_zaj). Vrhovi na zajedničkom podgrafu predstavljaju semantički i strukturno slične objekte uspoređenih podatkovnih modela, a lukovi prikazuju tip veze koji postoji među sličnim objektima.

Kreiranje zajedničkog podgraфа na temelju elemenata iz presjeka lukova i presjeka vrhova se provodi primjenom sljedeće funkcije:

```
grafPresjekaLukova: create_graph(vrhovi_zaj,lukovi_zaj,directed=true);
```

Algoritam pisan jezikom programskog alata wxMaxima provodi i poziva prethodno opisane funkcije i procedure, a izgleda ovako:

```
algoritam(g1,g2,veze1,veze2):=block(  
  [presjekLukovaDigrafova:intersection(setify(veze1),setify(veze2)),grafPresjekaLukova,  
   a1:length(lukovi_1),a2:length(lukovi_2),a3:length(lukovi_zaj),  
   a4:length(vrhovi_1),a5:length(vrhovi_2),a6:length(vrhovi_zaj),  
   a7:length(veze1),a8:length(veze2),  
   a9:length(podmat_1), a10:length(podmat_2)],  
  grafPresjekaLukova: create_graph(  
    vrhovi_zaj,  
    lukovi_zaj,  
    directed=true  
  ),  
  print("Graf koji je izveden iz prvog modela podataka:"),  
  draw_graph(g1,  
    show_weight=true,  
    vertex_size=3,  
    show_id=true,  
    edge_color="dark-green",  
    head_length=0.7,
```

```

    head_angle=10,
    text_color=blue ),
print("Matrica susjedstva grafa 1"),
print(matrica_grafa(a9,veze1)),
print("Graf koji je izveden iz drugog modela podataka:"),
    draw_graph(g2,
    show_weight=true,
    vertex_size=3,
    show_id=true,
    edge_color="dark-green",
    head_length=0.7,
    head_angle=10,
    text_color=blue ),
print("Matrica susjedstva grafa 2"),
print(matrica_grafa(a10,veze2)),
    print("Zajednicki podgraf modela podataka"),
    draw_graph(grafPresjekaLukova,
    show_weight=true,
    vertex_size=3,
    show_id=true,
    edge_color="dark-green",
    head_length=0.7,
    head_angle=10,
    text_color=blue ),
print("Matrica susjedstva zajednickog podgrafa modela podataka"),
print(matrica_grafa(a9,lukovi_zaj)),
    print("Mjera slicnosti lukova podgrafa odabranih semantički slicnih objekata prvog modela podataka
prema drugom:",a3/a1*100.0),
    print("Mjera slicnosti lukova podgrafa odabranih semantički slicnih objekata drugog modela podataka
prema prvom:",a3/a2*100.0),
    print("Mjera slicnosti vrhova podgrafa odabranih semantički slicnih objekata prvog modela podataka
prema drugom:",a6/a4*100.0),
    print("Mjera slicnosti vrhova podgrafa odabranih semantički slicnih objekata drugog modela podataka
prema prvom:",a6/a5*100.0),
    print("Vrhovi podgrafa odabranih semantički slicnih objekata prvog modela u zajednickom podgrafu
su:",vrhovi_1_u_presjeku),
    print("Nazivi vrhova podgrafa odabranih semantički slicnih objekata prvog modela u zajednickom
podgrafu su:",presjek_nazivi_vrhova_1),
    print("Vrhovi podgrafa odabranih semantički slicnih objekata drugog modela u zajednickom podgrafu
su:",vrhovi_2_u_presjeku),
    print("Nazivi vrhova podgrafa odabranih semantički slicnih objekata drugog modela u zajednickom
podgrafu su:",presjek_nazivi_vrhova_2),
    print(""))$

```

Algoritam s pokreće pozivanjem procedure:

```

algoritam(podgraf_1, podgraf_2, vezepodmat_1, vezepodmat_2);

```

7.4.2.3. Tumačenje rezultata usporedbe

Tumačenje rezultata provedbe se provodi u 4 koraka:

Korak 15: Analiza sličnosti lukova.

Izračunati sličnost podatkovnih modela s obzirom na broj lukova u početnim modelima i zajedničkom modelu.

Korak 16: Analiza sličnosti vrhova.

Izračunati sličnost podatkovnih modela s obzirom na broj vrhova u početnim modelima i zajedničkom modelu.


Korak 17: Tumačenje oznaka vrhova pomoću kataloga objekata.

Izraditi listu semantički i strukturno sličnih entiteta početnih grafova i zajedničkog podgrafa temeljem oznaka iz grafova i naziva svakog entiteta u početnom modelu.


Koraci 15 do 17 su integrirani u algoritam i nakon provedbe usporedbe prikazuju rezultate usporedbe prikazujući:

- grafove izvedene iz modela podataka na slikama 7.5. i 7.6. prema odabranim permutacijama,
- podgraf zajedničkih lukova i vrhova na slici 7.7.,
- matrice susjedstva,
- mjeru sličnosti lukova grafa prvog modela podataka prema drugom, izračunatu kao omjer ukupnog broja lukova prvog početnog grafa i podgrafa
- mjeru sličnosti lukova grafa drugog modela podataka prema prvom, izračunatu kao omjer ukupnog broja lukova drugog početnog grafa i podgrafa
- mjeru sličnosti vrhova grafa prvog modela podataka prema drugom, izračunatu kao omjer ukupnog broja vrhova prvog početnog grafa i podgrafa
- mjeru sličnosti vrhova grafa drugog modela podataka prema prvom, izračunatu kao omjer ukupnog broja vrhova drugog početnog grafa i podgrafa
- vrhove grafa prvog modela u zajedničkom grafu su
- nazive vrhova grafa prvog modela u zajedničkom grafu
- vrhove grafa drugog modela u zajedničkom grafu
- nazive vrhova grafa drugog modela u zajedničkom grafu.


Rezultati provedbe algoritma za analizirane modele podataka su prikazani u nastavku.



Slika 7.5.: Podgraf prvog početnog grafa izvedenog iz modela podataka visokog učilišta

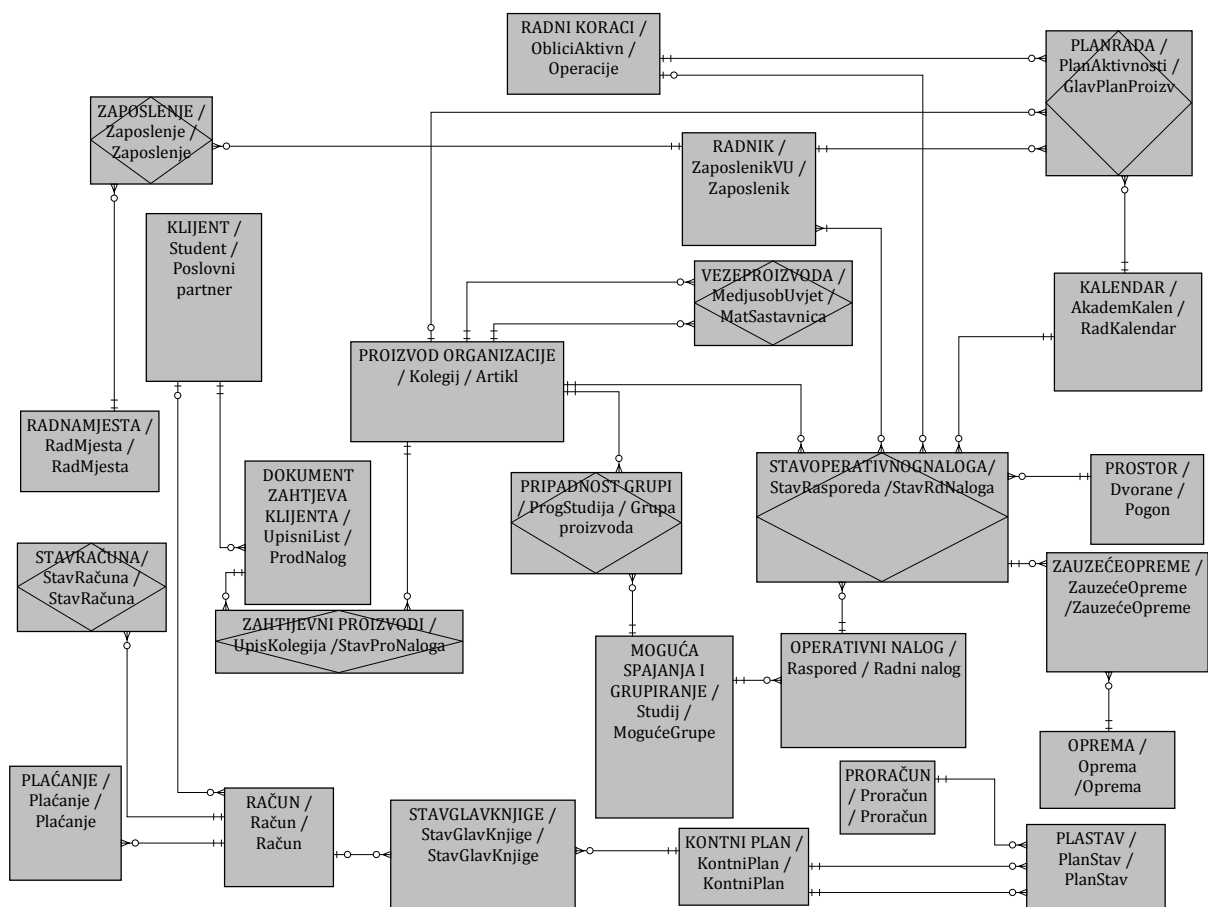


Slika 7.6.: Podgraf drugog početnog grafa izvedenog iz modela podataka proizvodnog poduzeća



Slika 7.7.: Zajednički podgraf modela podataka

Usporedbom osnovnih koncepata pronađen je podskup koncepata koji su zajednički ERP sustavima visokih učilišta i ERP sustavu proizvodnog poduzeća. Elementi tog podskupa mogu se smatrati obrascem (ili predloškom) objekata s vezama koje mogu biti primijenjen u različitim ERP sustavima. Na slici 7.8. je prikazan model podataka izveden iz zajedničkog podgraфа. Objekti tog podatkovnog modela su dobili novi generički naziv (ispisan velikim slovima) koji naznačava poslovnu ulogu objekta, kojem su pridodani i originalni nazivi objekata početnih modela (npr. KLIJENT/ Student/ Poslovni partner).



Slika 7.8.: Model podataka semantički i strukturno sličnih objekata izveden iz zajedničkog podgrafa

Koncepti prikazani na slici 7.8. se mogu smatrati obrascem (ili predloškom) objekata s vezama koje mogu biti primijenjeni u različitim ERP sustavima.

Sažetak rezultata koje daje algoritam glasi:

- Mjera sličnosti lukova grafa prvog modela podataka prema drugom: 30.76
- Mjera sličnosti lukova grafa drugog modela podataka prema prvom: 40.0
- Mjera sličnosti vrhova grafa prvog modela podataka prema drugom: 42.18
- Mjera sličnosti vrhova grafa drugog modela podataka prema prvom: 56.25
- Vrhovi grafa prvog modela u zajedničkom grafu su:
[45, 60, 25, 14, 33, 41, 21, 43, 44, 62, 23, 15, 17, 1, 38, 5, 22, 50, 20, 30, 51, 52, 61, 35, 28, 58, 57]
- Nazivi vrhova grafa prvog modela u zajedničkom grafu su:
[Student, ZaposlenikVU, Predmet, KontniPlan, Racun, StavGlavKnjige, Placanje, StavRacuna, StavRasporeda, ZauzećeOpreme, PlanStav, MedjusobUvjet, ObliciAktivn, AkademKalen, Raspored, Dvorane, PlanAktivnosti, UpisneKvot, Oprema, Proracun, UpisniList, UpisPredmeta, Zaposlenje, RadMjesta, ProgStudija, XPredmet, XKontniPlan]
- Vrhovi grafa drugog modela u zajedničkom grafu su:
[21, 46, 1, 7, 25, 30, 17, 36, 37, 48, 19, 8, 12, 26, 28, 20, 4, 18, 13, 24, 23, 35, 47, 27, 5, 41, 42]

- Nazivi vrhova grafa drugog modela u zajedničkom grafu su:
[PoslPartner, Zaposlenik, Artikl, KontniPlan, Racun, StavGlavKnjige, Placanje, StavRacuna, StavRadNaloga, ZauzeceOpreme, PlanStav, MatSastavnica, Operacije, RadKalendar, RadNalog, Pogoni, GlavPlanProiz, PlanProizProg, Oprema, Proracun, ProdNalog, StavProdNaloga, Zaposlenje, RadMjesta, GrupaProizv, XArtikl, XKontniPlan]

Kako smo uspjeli pronaći podgraf zajedničkih lukova i vrhova početnih grafova, možemo reći da smo pronašli maksimalne podgrafove početnih grafova koji su izomorfni.

Ako bi dobiveni podgraf bio prazan graf, onda među uspoređivanim grafovima i njihovim modelima podataka nema strukturne sličnosti. Ako je podgraf pravi podgraf nekog od početnih grafova, onda je taj graf u potpunosti strukturno sličan drugom grafu, odnosno onda je model podataka tog grafa u potpunosti sadržan u drugom modelu podataka.

Korak 18: Analiza srodnosti objekata temeljem broja zajedničkih veza.

Preostali vrhovi u presjeku predstavljaju entitete za koje je pretpostavljena semantička sličnost i temeljem nje dokazana strukturna sličnost s bar jednim drugim entitetom. Vrhovi i lukovi u presjeku čine novi zajednički graf koji je izomorfan minimalno jednom podgrafu grafa 1 i minimalno jednom podgrafu grafa 2.

Objekte modela koji pripadaju zajedničkom podgrafu možemo detaljnije razmotriti i odrediti srodnost kao mjeru sličnosti svakog objekta s obzirom na broj veza koje objekt ima u početnom modelu i broj veza koje objekt ima u zajedničkom modelu (podgrafu). Analiza se provodi za objekte modela podataka koji su češće referencirani nego što referenciraju druge objekte, odnosno za vrhove koji imaju veći outstupanj od instupnja, pomoću funkcije formirane kao u nastavku. Za pretpostaviti je da su češće referencirani objekti jaki objekti, koji predstavljaju matične podatke ili kataloge podataka.

```
referencirani: for a:1 thru length(vrhovi_zaj) do (
  if length(out_neighbors(lov_1[vrhovi_zaj[a]],graf_1))>= length(in_neighbors(lov_1[vrhovi_zaj[a]],graf_1))
  and length(out_neighbors(lov_1[vrhovi_zaj[a]],graf_1))>0 then (
    print(" 1. model "),
    print (("ID entiteta ("),lov_1[vrhovi_zaj[a]],(") "), (part (nazivi_vrhova_1,lov_1[vrhovi_zaj[a]])),(" se u
    pocetnom modelu 1 referencira u entitetima: ")),
    (izlazni1P: (out_neighbors(lov_1[vrhovi_zaj[a]],graf_1))),
    p1:length(izlazni1P),
    for b:1 thru length(izlazni1P) do (
      print ((izlazni1P[b]), (part (nazivi_vrhova_1,izlazni1P[b])))),
```

```

print ((" a u zajednickom modelu referencira u entitetima: ")),
(izlazniPGP: (out_neighbors(vrhovi_zaj[a],grafPresjekaLukova))),
p3: length(izlazniPGP),
for c:1 thru length(izlazniPGP) do (
print ((izlazniPGP[c]),(part(lov_1_nazivi,izlazniPGP[c])))),
), (print ("-----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: ", p4:p3/p1*100,"%")),
if length(out_neighbors(lov_2[vrhovi_zaj[a]],graf_2))>= length(in_neighbors(lov_2[vrhovi_zaj[a]],graf_2))
and length(out_neighbors(lov_2[vrhovi_zaj[a]],graf_2))>0 then (
print(" 2. model "),
print (("ID entiteta ("),lov_2[vrhovi_zaj[a]],(" "),(part (nazivi_vrhova_2,lov_2[vrhovi_zaj[a]])),(" se u
pocetnom modelu 2 referencira u entitetima: ")),
(izlazni2P: (out_neighbors(lov_2[vrhovi_zaj[a]],graf_2))),
p2:length(izlazni2P),
for b:1 thru length(izlazni2P) do (
print ((izlazni2P[b]), (part (nazivi_vrhova_2,izlazni2P[b])))),
print ((" a u zajednickom modelu referencira u entitetima: ")),
(izlazniPGP: (out_neighbors(vrhovi_zaj[a],grafPresjekaLukova))),
p3: length(izlazniPGP),
for c:1 thru length(izlazniPGP) do (
print ((izlazniPGP[c]),(part(lov_2_nazivi,izlazniPGP[c])))),
(print ("-----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: ", p4:p3/p2*100,"%"))));

```

Rezultat primjene funkcije referencirani je prikazan u tablici 7.13. Ona pokazuje vrijednosti mjere sličnosti entiteta u početnim i zajedničkom podatkovnom modelu. Mjera sličnosti se izračunava kao omjer broja veza entiteta (odnosno broja učestalosti referenciranja entiteta) u zajedničkom modelu i broja veza entiteta u početnom modelu u kojem se izvorno koristi.

Tablica 7.13.: Srodnost entiteta u početnim modelima i zajedničkom modelu

1. model	2. model
<p>(45) Student se u pocetnom modelu 1 referencira u entitetima:</p> <p>27PriznStudPrava</p> <p>51UpisniList</p> <p>19ObvezeStud</p> <p>59Zahtjev</p> <p>33Racun</p> <p>49TemaRada</p> <p>26PrijavaIspita</p> <p>53UpisStudenta</p> <p>a u zajednickom modelu referencira u entitetima:</p> <p>22UpisniList</p> <p>-----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: 12,5%</p>	<p>(21) PoslPartner se u pocetnom modelu 2 referencira u entitetima:</p> <p>40Ugovor</p> <p>25Racun</p> <p>10Narudzba</p> <p>15Otpremnica</p> <p>22Primka</p> <p>23ProdNalog</p> <p>a u zajednickom modelu referencira u entitetima:</p> <p>22ProdNalog</p> <p>-----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: 16,67%</p>

<p>(60) Zaposlenik VU se u početnom modelu 1 referencira u entitetima:</p> <p>40StatusPrijavIspita 22PlanAktivnosti 61Zaposlenje 3Autori 36RadNaProjektu 29Projekt 10IspitniRok 12IzborUZvanje 44StavRasporeda 49TemaRada a u zajedničkom modelu referencira u entitetima: 24Zaposlenje 9StavRasporeda -----SRODNOST entiteta u početnom i zajedničkom modelu iznosi: 20%</p>	<p>(46) Zaposlenik se u početnom modelu 2 referencira u entitetima:</p> <p>37StavRadNaloga 47Zaposlenje 3dodjelOvlas 45Zahtjevnica a u zajedničkom modelu referencira u entitetima: 24Zaposlenje 9StavRadNaloga -----SRODNOST entiteta u početnom i zajedničkom modelu iznosi: 50%</p>
<p>(25) Predmet se u početnom modelu 1 referencira u entitetima:</p> <p>28ProgStudija 8IshUcenjPredmeta 22PlanAktivnosti 52UpisPredmeta 49TemaRada 15MedjusobUvjet 44StavRasporeda 10IspitniRok a u zajedničkom modelu referencira u entitetima: 27ProgStudija 23UpisPredmeta 12MedjusobUvjet 9StavRasporeda -----SRODNOST entiteta u početnom i zajedničkom modelu iznosi: 50%</p>	<p>(1) Artikal se u početnom modelu 2 referencira u entitetima:</p> <p>35StavProdNaloga 38StavZahtjev 37StavRadNaloga 36StavRacuna 5GrupaProizv 4GlavPlanProiz 2Cjenik 32StavNarudz 31StavIzdat 33StavOtprem 34StavPrim 8MatSastavnica a u zajedničkom modelu referencira u entitetima: 27GrupaProizv 23StavProdNaloga 12MatSastavnica 9StavRadNaloga -----SRODNOST entiteta u početnom i zajedničkom modelu iznosi: 33,33%</p>
<p>(14) KontniPlan se u početnom modelu 1 referencira u entitetima:</p> <p>23PlanStav 41StavGlavKnjige a u zajedničkom modelu referencira u entitetima: 11PlanStav 6StavGlavKnjige -----SRODNOST entiteta u početnom i zajedničkom modelu iznosi: 100%</p>	<p>(7) KontniPlan se u početnom modelu 2 referencira u entitetima:</p> <p>19PlanStav 30StavGlavKnjige a u zajedničkom modelu referencira u entitetima: 11PlanStav 6StavGlavKnjige -----SRODNOST entiteta u početnom i zajedničkom modelu iznosi: 100%</p>
<p>(33) Racun se u početnom modelu 1 referencira u entitetima:</p> <p>43StavRacuna 41StavGlavKnjige 21Placanje a u zajedničkom modelu referencira u entitetima: 8StavRacuna 7Placanje -----SRODNOST entiteta u početnom i zajedničkom modelu iznosi: 66,66%</p>	<p>(25) Racun se u početnom modelu 2 referencira u entitetima:</p> <p>17Placanje 30StavGlavKnjige 36StavRacuna a u zajedničkom modelu referencira u entitetima: 8StavRacuna 7Placanje -----SRODNOST entiteta u početnom i zajedničkom modelu iznosi: 66,66%</p>

<p>(17) <i>ObliciAktivn se u pocetnom modelu 1 referencira u entitetima:</i> 22PlanAktivnosti 44StavRasporeda <i>a u zajednickom modelu referencira u entitetima:</i> 17PlanAktivnosti -----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: 50%</p>	<p>(12) <i>Operacije se u pocetnom modelu 2 referencira u entitetima:</i> 37StavRadNaloga 4GlavPlanProiz <i>a u zajednickom modelu referencira u entitetima:</i> 17GlavPlanProiz -----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: 50%</p>
<p>(1) <i>AkademKalen se u pocetnom modelu 1 referencira u entitetima:</i> 50UpisneKvote 10IspitniRok 22PlanAktivnosti 44StavRasporeda <i>a u zajednickom modelu referencira u entitetima:</i> 18UpisneKvote 17PlanAktivnosti 9StavRasporeda -----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: 75%</p>	<p>(26) <i>RadKalendar se u pocetnom modelu 2 referencira u entitetima:</i> 4GlavPlanProiz 18PlanProizProg 37StavRadNaloga <i>a u zajednickom modelu referencira u entitetima:</i> 18PlanProizProg 17GlavPlanProiz 9StavRadNaloga -----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: 100%</p>
<p>(38) <i>Raspored se u pocetnom modelu 1 referencira u entitetima:</i> 44StavRasporeda <i>a u zajednickom modelu referencira u entitetima:</i> 9StavRasporeda -----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: 100%</p>	<p>(28) <i>RadNalog se u pocetnom modelu 2 referencira u entitetima:</i> 37StavRadNaloga <i>a u zajednickom modelu referencira u entitetima:</i> 9StavRadNaloga -----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: 100%</p>
<p>(5) <i>Dvorane se u pocetnom modelu 1 referencira u entitetima:</i> 44StavRasporeda <i>a u zajednickom modelu referencira u entitetima:</i> 9StavRasporeda -----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: 100%</p>	<p>(20) <i>Pogoni se u pocetnom modelu 2 referencira u entitetima:</i> 37StavRadNaloga <i>a u zajednickom modelu referencira u entitetima:</i> 9StavRadNaloga -----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: 100%</p>
<p>(30) <i>Proracun se u pocetnom modelu 1 referencira u entitetima:</i> 23PlanStav <i>a u zajednickom modelu referencira u entitetima:</i> 11PlanStav -----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: 100%</p>	<p>(24) <i>Proracun se u pocetnom modelu 2 referencira u entitetima:</i> 19PlanStav <i>a u zajednickom modelu referencira u entitetima:</i> 11PlanStav -----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: 100%</p>
<p>(20) <i>Oprema se u pocetnom modelu 1 referencira u entitetima:</i> 62ZauzeceOpreme <i>a u zajednickom modelu referencira u entitetima:</i> 10ZauzeceOpreme -----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: 100%</p>	<p>(13) <i>Oprema se u pocetnom modelu 2 referencira u entitetima:</i> 48ZauzeceOpreme <i>a u zajednickom modelu referencira u entitetima:</i> 10ZauzeceOpreme -----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: 100%</p>
<p>(51) <i>UpisniList se u pocetnom modelu 1 referencira u entitetima:</i> 52UpisPredmeta <i>a u zajednickom modelu referencira u entitetima:</i> 23UpisPredmeta -----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: 100%</p>	<p>(23) <i>ProdNalog se u pocetnom modelu 2 referencira u entitetima:</i> 35StavProdNaloga <i>a u zajednickom modelu referencira u entitetima:</i> 23StavProdNaloga -----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: 100%</p>

<p>(35) RadMjesta se u pocetnom modelu 1 referencira u entitetima: 61Zaposlenje a u zajednickom modelu referencira u entitetima: 24Zaposlenje -----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: 100%</p>	<p>(27) RadMjesta se u pocetnom modelu 2 referencira u entitetima: 47Zaposlenje a u zajednickom modelu referencira u entitetima: 24Zaposlenje -----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: 100%</p>
<p>(58) XPredmet se u pocetnom modelu 1 referencira u entitetima: 15MedjusobUvjet a u zajednickom modelu referencira u entitetima: 12MedjusobUvjet -----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: 100%</p>	<p>(41) XArtikl se u pocetnom modelu 2 referencira u entitetima: 8MatSastavnica a u zajednickom modelu referencira u entitetima: 12MatSastavnica -----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: 100%</p>
<p>(57) XKontniPlan se u pocetnom modelu 1 referencira u entitetima: 14KontniPlan a u zajednickom modelu referencira u entitetima: 4KontniPlan -----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: 100%</p>	<p>(42) XKontniPlan se u pocetnom modelu 2 referencira u entitetima: 7KontniPlan a u zajednickom modelu referencira u entitetima: 4KontniPlan -----SRODNOST entiteta u pocetnom i zajednickom modelu iznosi: 100%</p>

7.4.3. Ograničenja, rizici i inačice postupka određivanja strukturne sličnosti istovrsnih grafičkih modela

Postupak određivanja semantičke i strukturne sličnosti ima ograničenja, rizike i inačice.

Ograničenja vezana uz model podataka i algoritam usporedbe strukturne sličnosti su sljedeća:

- **Modeli moraju biti izrađeni istom metodom modeliranja.** U ovom slučaju su modeli izrađeni ERA metodom kao logički modeli podataka. Objekti i njihove veze oslikavaju poslovna pravila (npr. student može upisati 1 ili više studija).
- **Modeli trebaju opisivati semantički analogne pojmove,** odnosno slične ili istoznačne pojmove koji imaju sličan poslovni i funkcijski značaj unutar promatrane organizacije. Budući da modeli podataka proizlaze iz poslovnih pravila, usporedbom i predloženim tehnikama za određivanje semantičke sličnosti (tablica 7.1.) može provesti provjera ovog preduvjeta usporedbe.
- **Modeli ne smiju sadržavati veze koje se ne mogu realizirati u relacijskoj bazi podataka.** Svaka veza entiteta tipa M:N se prikladnom transformacijom mora prevesti u dvije veze tipa 1:M i 1:N. Transformacija se provodi dodavanjem entiteta koji opisuje detaljno opisuje, kvalificira ili kvantificira vezu objekata. Ovo

ograničenje određuje kvalitetu modela podataka, a ne utječe izravno na rezultate usporedbe, ako je veza zapisana kao dva luka između oba vrha koji predstavljaju entitete.

- **Modeli ne smiju sadržavati unarne veze niti višestruke veze između dva entiteta.** Ovo ograničenje proizlazi iz ograničenja alata za usporedbu grafova koji ne prikazuje višestruke istosmjerne veze čvorova usmjerenog grafa ili petlje. Ako u modelu postoje unarne ili višestruke veze, onda treba dodati nove entitete sa strukturom naziva "XNaziventiteta" i prema njemu dodati vezu koja narušava ovo pravilo (vidjeti veze entiteta KontniPlan- XKontniPlan, Predmet-Međusobna uvjetovanost-XPredmet).
- **Model mora konzistentno preslikavati poslovna pravila kod modeliranja veza.** Kod izrade modela podataka u Cool:Bizu ili drugom alatu valja paziti na smjer crtanja veze (od referenciranog ka referencirajućem entitetu). Sve veze između entiteta se kreiraju od entiteta iz kojeg se vrijednost atributa referencira i prenosi prema odredišnom entitetu u čiji se atribut odabrana vrijednost zapisuje (npr. predmet ->stavka rasporeda).
- **Model mora omogućiti razlikovanje načina učešća ključnog svojstva.** Alat za izradu modela podataka treba omogućiti razlikovanje načina sudjelovanja identifikacijskog svojstva kao primarnog ili vanjskog atributa (u relacijskom smislu). Ako alat za izradu modela to ne razlikuje, onda veze koje opisuju korištenje atributa kao primarnog ključa u relacijskom smislu trebaju sadržavati oznaku P ili V za tip korištenja vrijednosti atributa (kasnije kao primarni ili kao vanjski) u nazivu veze.

Rizici koje moramo uzeti u obzir su:

- **Loša kvaliteta podatkovnih modela.** Kvaliteta podatkovnih modela proizlazi iz dosljednosti u poštivanju pravila modeliranja podataka. Zato odabir modela za usporedbu predstavlja jedan od rizika.
- **Nedostupnost usporedivih modela.** Pod ovim faktorom rizika podrazumijevamo nedostupnost kvalitetnog modela za usporedbu ili usporedivog modela po kriteriju postojanja semantičke sličnosti objekata.
- **Pojava greške kod određivanja semantički sličnih objekata** je rizik za čije je smanjenje predviđena korektivna mjera. Ako postoji sumnja u odabir semantički

sličnih objekata, onda se rizik može smanjiti na način da se algoritam provede više puta sa različitim kombinacijama semantički sličnih objekata uzimajući u obzir rezultate analize strukturne sličnosti.

- **Odabrani modeli podataka su presloženi, odnosno obuhvaćaju prevelik broj objekata.** Algoritam se temelji na teoriji grafova i određivanju najvećeg podgrafa izomornog početnim grafovima izvedenim iz modela podataka. Složenost postupka traženja izomorfizama grafova raste s brojem vrhova grafova. Kako se u podatkovnim modelima broj elemenata može kretati od 2 na dalje, traženje izomornih podgrafa postaje općenito težak problem ako nema kriterija koji pojednostavljaju postupak. Kriterij koji omogućava traženje izomornih podgrafa i koji je ugrađen u predloženi postupak je kriterij postojanja semantičke sličnosti objekata. Temeljem semantičke sličnosti se kreiraju liste odabranih vrhova koje omogućavaju renumeraciju vrhova i usporedivost lukova grafova pomoću funkcije presjeka nad matricama permutacije.

Inačice postupka određivanja strukturne i semantičke sličnosti su sljedeće:

- **Uključivanje tipova veza prema načinu sudjelovanja svojstva** – ako je u usporedbi važno sudjeluje li svojstvo kao primarni ili vanjski ključni atribut u nekom odnosu entiteta (u relacijskom smislu). Provedba ovog postroženja usporedbe se može realizirati tako da se katalog tipova veza dodaju odgovarajuće stavke, te prema tome dodaju i novi elementi koji utječu na težine lukova. Budući da je ovo postroženje početnog algoritma, rezultati usporedbe će pokazivati manju sličnost lukova i vrhova (entiteta i njihovih veza) jer će se u tom slučaju uz smjer luka (smjer referenciranja identifikacijskog svojstva) analizirati i način učešća svojstva (opcionalno ili obvezno referenciranje).
- **Pojednostavljenje tipova veza prema načinu učešća svojstva** – provodi se u slučaju kada nije važno je li veza obvezna ili opcionalna, jer je opcionalna veza samo jedan tip obvezne veze u kojoj je vrijednost referenciranog atributa jednaka nuli (ili drugoj vrijednosti koja se uzima kao standardna ili *engl. default*). Provedba ovog pojednostavljenja se može realizirati tako da katalog tipova veza ima samo dvije stavke koje se odnose na način sudjelovanja identifikacijskog svojstva (primarni ili vanjski ključ), te prema tome i dvije moguće težine lukova. Budući da je ovo

pojednostavljenje početnog algoritma, rezultati usporedbe će pokazivati veću sličnost lukova i vrhova (entiteta i njihovih veza) jer će se u tom slučaju analizirati samo smjer luka (smjer referenciranja identifikacijskog svojstva) i način sudjelovanja svojstva (referenciranje svojstva kao primarnog ili vanjskog ključnog atributa).

- **Apsolutno pojednostavljenje veza** – vrijedi za slučaj kada je važno promatrati samo smjer referenciranja, a način sudjelovanja ključnog atributa i način učešća nisu relevantni. Ovo je najopsežnije pojednostavljenje veza, gdje je dovoljna samo jedna težina veze. Rezultati usporedbe će pokazivati najveću sličnost lukova i vrhova (entiteta i njihovih veza), jer će se u tom slučaju analizirati samo smjer luka (smjer referenciranja identifikacijskog svojstva).
- **Usporedba više od dva podatkovna modela** je moguća jer se algoritam temelji na određivanju presjeka skupova veza. Pritom nije važno koliko skupova veza treba usporediti, već je važno samo da su u skupovima veze opisane izjednačenim numeričkim oznakama vrhova i tipova veza.

7.5. Osvrt na hipotezu o semantičkoj i strukturnoj sličnosti koncepata ERP sustava

Polazna hipoteza je glasila da se sustavi planiranja i upravljanja resursima visokih učilišta strukturno i semantički temelje na osnovnim konceptima ERP sustava, ali istovremeno imaju i vlastite koncepte koji ih u ontološkom smislu čine posebnom klasom takvih sustava.

Hipoteza je najprije testirana pomoću 4 predložene metode za određivanje semantičke sličnosti. Primjenom metoda je utvrđena semantička sličnost 27 objekata s oba podatkovna modela (u odnosu na 62 entiteta iz modela podataka VU i 44 entiteta u modelu proizvodnog poduzeća). Za te je semantički slične objekte, primjenom algoritma za određivanje strukturne sličnosti temeljenog na teoriji grafova, testirana strukturna sličnost. Kako je pronađen neprazan skup presjeka veza objekata, odnosno zajednički podgraf koji je izomorfan izdvojenim podgrafovima nastalim iz početnih modela podataka, potvrđen je dio hipoteze da među konceptima podatkovnih modela postoje

semantički i strukturno slični objekti i veze. Kako zajednički podgraf nije izomorfan sa početnim grafom izvedenim iz modela podatka visokih učilišta, zaključuje se da u podatkovnom modelu visokih učilišta postoje objekti koji predstavljaju koncepte specifične za ERP sustave visokih učilišta. Time je dokazana polazna hipoteza.

Zajednički podgraf obuhvaća semantički i strukturno slične objekte iz oba početna modela podataka i njihove veze. Ako se prema objektima i vezama iz podatkovnog modela kreira baza podataka, onda ta baza podataka može biti osnovica (ili kostur) koji se nadograđuje specifičnim konceptima promatrane organizacije. Objekti i veze obuhvaćene zajedničkim modelom su predložak podataka (*engl. Data Pattern*) koji upravo zbog relativno velikog broja veza i objekata (vidjeti rezultate primjene algoritma i mjere sličnosti modela podataka) može biti primjenjiv i u drugim podatkovnim modelima.

8. Interoperabilnost ERP sustava i integracija s drugim informacijskim (pod)sustavima

U ovom poglavlju se razmatraju primjenjive razine i modeli interoperabilnosti sustava planiranja i upravljanja resursima visokih učilišta kao i mogućnost integracije aplikacija ERP sustava visokih učilišta s drugim aplikacijama implementiranih informacijskih sustava.

8.1. Definicija i razine interoperabilnosti


Prema Vrčeku [92] „interoperabilnost je sposobnost poslovnih procesa i informacijskih sustava koji ih podržavaju da razmjenjuju podatke, informacije i znanje“, a autor razlikuje podatkovnu (tehničku), semantičku, procesnu i pravnu interoperabilnost.

Prema autorima Wang, Tolk, Wang [95], postoji 6 razina modela konceptualne interoperabilnosti (tablica 8.1.).

Tablica 8.1. Razine konceptualne interoperabilnosti prema Wang, Tolk, Wang [95]

Razina interoperabilnosti	Deskriptivni opis	Osnovni pristupi inženjeringu i modeliranju
Konceptualna interoperabilnost	Sustavi u potpunosti prepoznaju podatke, procese, kontekst korištenja podataka, a njihovi modeli dijele iste pretpostavke i spoznaje o objektima modela.	DoDAF; Military Mission to Means Framework; Platform Independent Models of the Model Driven Architecture; SysML
Dinamička interoperabilnost	Sustavi mogu prepoznati promjene konteksta podataka te i s vremenom mijenjati način kreiranja i korištenja podataka.	Ontology for Services; UML artifacts; DEVS; complete UML; BOM
Pragmatička interoperabilnost	Sustavi prepoznaju i razumiju kontekst korištenja podataka prepoznajući događaje i stanja vezana uz obradu podataka.	Taxonomies; Ontology; UML artifacts, in particular sequence diagrams; DEVS; OWL; MDA
Semantička interoperabilnost	Koriste se zajednički katalozi podataka čime je omogućeno semantičko uparivanje i tumačenje razmijenjenih podataka.	Common Reference Model, such as C2IEDM and CADM; Dictionaries; Glossaries; Protocol Data Units; RPR FOM
Sintaktička interoperabilnost	Dogovoren je protokol razmjene podataka koji obuhvaća tip, oblik i redoslijed razmjene grupa podataka.	XML; HLA OMT; Interface Description Language; COR-BA; SOAP
Tehnička interoperabilnost	Postoji tehnička infrastruktura i omogućena je razmjena podataka između informacijskih sustava	Network connection standards such as HTTP; TCP/IP; UDP/IP etc.
Nulta razina interoperabilnosti	Nema interoperabilnosti	NA

Europski okvir za interoperabilnost (*engl. European Interoperability Framework for European Public Services, EIF* [26]), definira interoperabilnost kao sposobnost organizacija da zajednički djeluju ka ostvarenju unaprijed dogovorenih ciljeva, koristeći informacijske sustave dizajnirane na način da tijekom potpore poslovnim procesima aplikacije razmjenjuju i dijele informacije, podatke i znanje²⁴. Nadalje, prema EIF-u, okvir za interoperabilnost je dogovoreni pristup interoperabilnosti koji omogućava javnim službama dijeljenje podataka, a okvir obuhvaća zajednički rječnik, zajedničke koncepte, principe, procedure, smjernice, preporuke i prakse. Razine interoperabilnosti prema EIF-u su pravna, organizacijska, semantička i tehnička interoperabilnost, a svaka razina zahtijeva odgovarajuće usklađivanje organizacija prema tome koju razinu interoperabilnosti žele i mogu ostvariti u okruženju u kojem djeluju. Prikaz razina interoperabilnosti prema EIF-u je dan na slici 8.1.



Slika 8.1.: Razine interoperabilnosti prema EIFu

Prema Federal Enterprise Architecture (skraćeno FEA, [30]), tri su elementa važna za ostvarenje integracije i interoperabilnosti: 1) integracija koja se veže uz povezivanje aplikacija informacijskog sustava, 2) interoperabilnost je vezana uz podatkovnu

²⁴ "Interoperability, within the context of European Public Services delivery, is the ability of disparate and diverse organisations to interact towards mutually beneficial and agreed common goals, involving the sharing of information and knowledge between the organisations, through the business processes they support, by means of the exchange of data between their respective ICT systems." [26]

infrastrukturu nad kojom rade aplikacije IS-a, i 3) sučelja koja omogućavaju servisno orijentirani pristup podatkovnom i aplikativnom povezivanju.

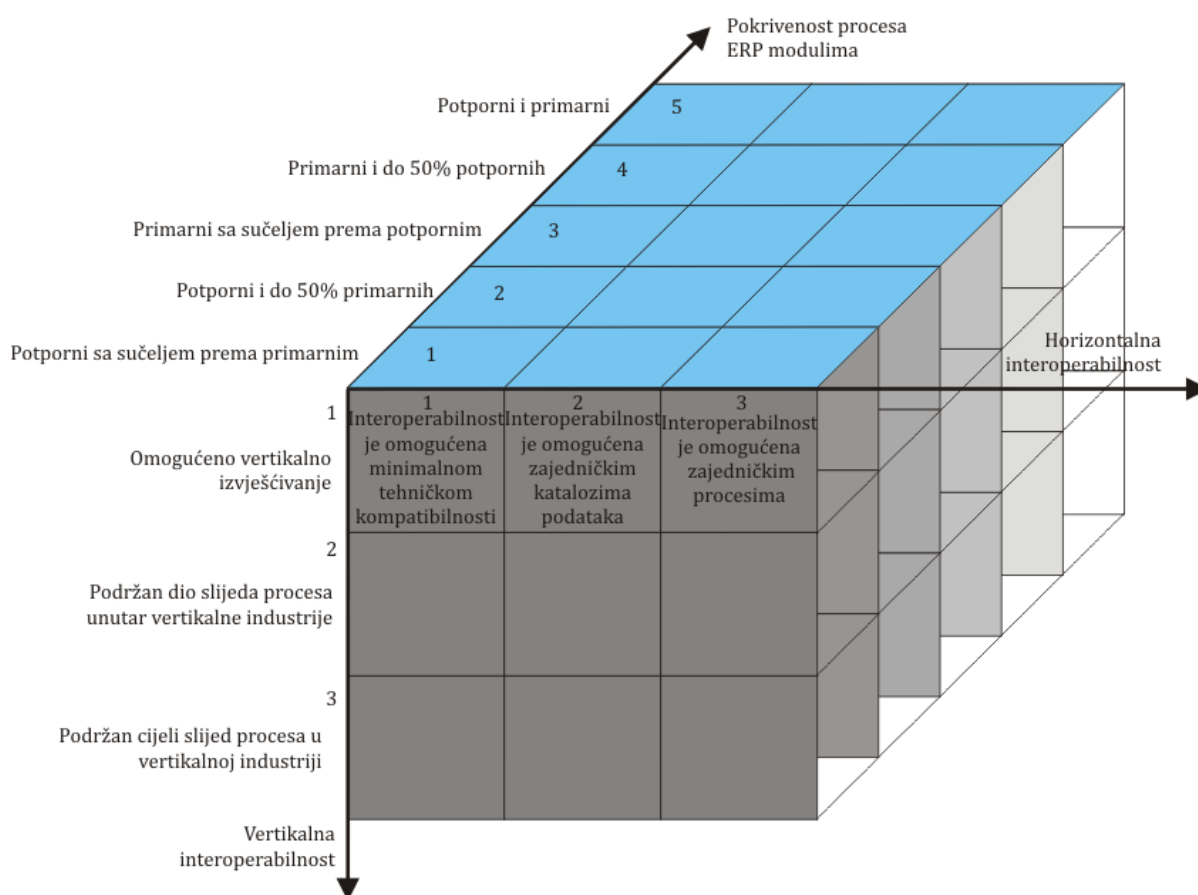
Prema TOGAFu (*engl. The Open Group Architecture Framework, skraćeno TOGAF, [87]*), postoje 4 oblika interoperabilnosti i integracije:

- **Prezentacijska integracija i interoperabilnost** (*engl. Presentation Integration/ Interoperability*) – povezanost sustava se ostvaruje pomoću portala koji korisniku omogućavaju prividno jedinstven pristup aplikacijama i podacima.
- **Podatkovna integracija i interoperabilnost** (*engl. Information Integration/ Interoperability*) – povezanost sustava se ostvaruje tako da se internim servisima omogući prikupljanje i povezivanje podatka koji onda naizgled korisniku bivaju isporučeni unutar pokrenute aplikacije.
- **Aplikativna integracija i interoperabilnost** (*engl. Application Integration/ Interoperability*) - aplikacije sustava su dizajnirane tako da uvijek pokrivaju samo jednu funkciju, što im omogućava višestruko pozivanje gdje god je to potrebno (npr. aplikacija služi za unos podataka o novom studentu, a ta aplikacija se pokreće kod unosa novog studenta bilo kojeg studija). Povezanost sustava je ostvarena tako da su aplikacije integrirane u cjeline koje prate slijed izvođenja poslovnih procesa, što onda podrazumijeva da se neke aplikacije mogu pozivati više puta iz različitih drugih aplikacija.
- **Tehnička integracija i interoperabilnost** (*engl. Technical Integration/ Interoperability*) podrazumijeva povezanost sustava temeljenu na zajedničkim metodama, alatima i servisima za razmjenu i obradu podataka.

Iako se mogu složiti sa navedenim definicijama interoperabilnosti, smatram da je potrebno razmatrati interoperabilnost kao svojstvo informacijskog sustava da bez obzira na organizacijska ograničenja, već u odnosu na slijed procesa zbog kojih je interoperabilnost nužna, omogući dostupnost podataka i aplikacija za rad nad podacima. U tom kontekstu valja uvesti pojmove horizontalne i vertikalne interoperabilnosti te su zato u sljedećem poglavlju dane definicije tih novih pojmova.

8.2. Interoperabilnost ERP-a za visoka učilišta

Inicijalne mogućnosti i ponuđene funkcionalnosti ERP sustava ne donose organizaciji nikakvu novu vrijednost ako ERP sustav ne može podržavati poslovanje organizacije na način kako se to traži u modelu procesa. ERP sustav oživljava tek implementacijom kombinacija funkcionalnosti koje su manje ili više prilagođene potrebama organizacije. Integracijom modula (aplikacija ERP sustava) ostvaruje se sposobnost programskog alata da podrži izvođenje cjelokupnog slijeda procesa. Ipak, integracija aplikacija može biti usmjerena i ostvarena na različite načine, ovisno o tome što se očekuje od informacijskog sustava. Okvir za ujednačavanje očekivanja kupca i mogućnosti realizacije ponuditelja ERP sustava je prikazan na slici 8.2. On omogućava identifikaciju i odabir potrebne razine interoperabilnosti organizacija pomoću njihovih informacijskih sustava, na temelju čega se onda može planirati integracija aplikativnog sloja IS-a.



Slika 8.2.: Okvir za pozicioniranje očekivanja i mogućnosti ERP sustava

Prva dimenzija kocke okvira se odnosi na pokrivenost procesa organizacije ERP modulima. Ovaj kriterij je odabran zato što je ERP definiran opsegom implementiranih funkcionalnosti za potporu poslovnim funkcijama i procesima, pa tako možemo razlikovati ERP koji pokriva samo neke poslovne funkcije i njihove procese i ERP koji je namijenjen potpori svih poslovnih funkcija i procesa poduzeća.

Razine potpore procesima se mogu definirati i s obzirom na doprinos procesa ostvarenju misije organizacije, odnosno s obzirom na Porterovu klasifikaciju na potporne i primarne procese:

1. Podržani su potporni procesi te je implementirano sučelje prema primarnim procesima (što znači da primarni procesi mogu biti ili neinformatizirani ili podržani nekim drugim informacijskim sustavom);
2. Podržani su potporni procesi te do 50% primarnih procesa;
3. Podržani su primarni procesi te je implementirano sučelje prema potpornim procesima (što znači da potporni procesi mogu biti ili neinformatizirani ili podržani nekim drugim informacijskim sustavom);
4. Podržani su primarni procesi te do 50% potpornih procesa;
5. Podržani su svi i primarni i potporni procesi.

Za druge dvije dimenzije je važan aspekt integracije i interoperabilnosti informacijskog sustava organizacije s obzirom na vrstu procesa koje IS podržava. Prema autorima Laguna i Marklund [51], postoje tri tipa procesa:

1. Individualni procesi koje izvršavaju pojedinci. Primjer individualnog procesa je Održavati ispite kojeg izvodi pojedinac, nastavnik.
2. Funkcionalni procesi koji se izvršavaju unutar jedne organizacijske jedinice. Primjer funkcionalnog procesa je Izvoditi nastavu jer u izvođenju tog procesa sudjeluju samo nastavnici visokog učilišta, koji obično propadaju i samo jednoj katedri.
3. Multifunkcionalni procesi koji se izvršavaju neovisno o ograničenjima organizacijske strukture, odnosno njihovo izvođenje nije ograničeno na jedan odjel, već u izvedbi sudjeluje nekoliko funkcionalno različitih organizacijskih jedinica. Tipičan primjer multifunkcionalnog procesa je proces Napredovati u zvanju, jer u njegovom izvođenju sudjeluju i članovi povjerenstava unutar i izvan

visokog učilišta (odnosno članovi nekog drugog visokog učilišta), organizacijska jedinica visokog učilišta zadužena za pravne poslove i uprava visokog učilišta, pojedinac – znanstvenik te druge institucije koje sudjeluju u odlučivanju kao što su Sveučilište ili nadležno Ministarstvo.

Na temelju ovih triju tipova procesa možemo zaključiti da postoji potreba razmatranja sposobnosti interoperabilnosti različitih organizacija uključenih u izvedbu nekog procesa u jednu funkcionalnu cjelinu bez obzira na ograničenja organizacijske strukture i složenosti poslova, odnosno na uključenost različitih sudionika u izvedbu procesa. U tom kontekstu valja uvesti termine horizontalne i vertikalne interoperabilnosti koje se odnose na druge dvije dimenzije kocke okvira.

Druga dimenzija se odnosi na horizontalnu interoperabilnost. Horizontalna interoperabilnost je oblik povezivanja organizacija u **jednu funkcionalnu cjelinu radi izvođenja procesa na istoj razini izvođenja, upravljanja ili odlučivanja** bez obzira na organizacijska ograničenja (pripadnost izvršitelja organizacijskoj jedinici ili organizaciji, odgovornost organizacijske jedinice za proces i sl.). Primjer kada se od alata očekuje ovo svojstvo je sljedeća: „Studij izvode dva ili više visokih učilišta (visoko učilišta A, visoko učilište B,...) kao ravnopravni subjekti. Aplikacija mora biti integrirana na način da osigurava potrebnu razinu interoperabilnosti dviju pravnih osoba: visokog učilišta A i visokog učilišta B, a radi potpore zajedničkim poslovnim procesima vezanim uz nastavnu djelatnost.“ Razine horizontalne interoperabilnosti su sljedeće:

1. Horizontalna interoperabilnost je omogućena minimalnom tehničkom kompatibilnošću informatičke infrastrukture. Za dani primjer to znači da dvije organizacije moraju imati tehničke preduvjete za komunikacijsko povezivanje, te pristup zajedničkoj bazi podataka.
2. Horizontalna interoperabilnost je omogućena zajedničkim katalozima podataka, odnosno kompatibilnošću informacijske infrastrukture. Za dani primjer to znači da dvije organizacije moraju imati minimalnu tehničku kompatibilnost informatičke infrastrukture i moraju koristiti iste podatkovne kataloge koji im omogućavaju da iste podatke tumače na isti način.
3. Horizontalna interoperabilnost je omogućena zajedničkom odgovornošću i aktivnostima procesa u kojem svi sudionici djeluju ravnopravno i neovisno o

organizacijskoj pripadnosti. Za dani primjer to znači da dvije organizacije moraju imati minimalnu tehničku kompatibilnost informatičke infrastrukture, da moraju koristiti iste podatkovne kataloge koji im omogućavaju da iste podatke tumače na isti način te da moraju imati ista prava za pristup i rad s aplikacijama koje se izvode nad podacima zajedničke baze podataka.

Treća dimenzija se odnosi na vertikalnu interoperabilnost. Vertikalna interoperabilnost je oblik povezivanja organizacija u **jednu funkcionalnu cjelinu radi izvođenja procesa kroz različite razine izvođenja, upravljanja i odlučivanja** bez obzira na organizacijska ograničenja. Vertikalna interoperabilnost se odnosi na interoperabilnost promatrane organizacije unutar vertikalne industrije u kojoj organizacija djeluje. Vertikalnu industriju neke organizacije čine druge organizacije koje imaju ili svojstvo dobavljača (za visoka učilišta dobavljačem možemo smatrati organizaciju za provedbu državne mature, srednje škole, ili npr. druga visoka učilišta koja produciraju buduće zaposlenike) ili svojstvo kupca (investitori, nadležna ministarstva, Sveučilište). Primjer kada se od alata očekuje ovo svojstvo je sljedeća: „Sastavnice visokog učilišta planiraju financijski proračun i dostavljaju ga na odobrenje nadređenoj instituciji Sveučilištu. Sveučilište planira svoj proračun u sklopu smjernica i ograničenja od nadležnog ministarstva. Sastavnice, Sveučilište i nadležno ministarstvo tvore vertikalnu industriju visokog obrazovanja čiji su procesi značajno povezani te se od alata očekuje potpora cjelokupnom procesu planiranja financija bez prekida u smislu prijepisa ili neke druge slične operacije konverzije nad podacima.“ Razine vertikalne interoperabilnosti su sljedeće:

1. Vertikalna interoperabilnost je omogućena u jednom smjeru alatima za izvješćivanje bez povratne upravljačke veze. Za dani primjer to znači da je omogućeno izvješćivanje prema Sveučilišta, nadležnom ministarstvu ili investitoru znanstveno istraživačkog ili komercijalnog projekta.
2. Vertikalna interoperabilnost je omogućena tako da podržava dio slijeda procesa, odnosno samo nekih organizacija unutar vertikalne industrije. To znači da je komunikacija dvosmjerna i ne odnosi se samo na izvješćivanje, već i zajedničko planiranje ili upravljanje resursima, ali ne omogućava cjelokupno praćenje po cijelom životnom ciklusu resursa.

3. Vertikalna interoperabilnost je omogućena tako da podržava cjelokupni slijed procesa, odnosno svih organizacija unutar vertikalne industrije koje su uključene u izvedbu procesa. To znači da je komunikacija dvosmjerna, da se odnosi na upravljanje cjelovitim slijedom poslovnih procesa tj. zajedničko planiranje, prikupljanje, korištenje, obnavljanje i nestajanje resursima, odnosno omogućava cjelokupno praćenje po cijelom životnom ciklusu resursa.

Na visokim učilištima postoji nekoliko složenih procesa koji zahtijevaju visoku razinu interoperabilnosti informacijskih sustava različitih sudionika. Neki od tih procesa su Planirati proračun, proces Isplate plaća (koji se izvodi kod nadležnog ministarstva), Izvoditi nastavu (ako u izvedbi programa studija sudjeluje više visokih učilišta), te Napredovati u zvanju.

Primjer složenog multifunkcionalnog procesa „Napredovati u zvanju“ je dan na slici 8.3. Nazivi iznad simbola procesa/aktivnosti prikazuju radna mjesta i druge različite sudionike u procesu, dok se ostale oznake tumače prema tablici 3.3.

Proces se izvodi kroz nekoliko upravljačkih razina unutar visokog učilišta (od tajnika fakulteta do fakultetskog vijeća) i na nekoliko institucija unutar sustava (npr. na visokom učilištu, u Povjerenstvima, na Sveučilištu). Ako cjeloviti proces treba biti podržan informacijskim sustavom, onda mora biti omogućena horizontalna i vertikalna interoperabilnost informacijskih sustava koji podržavaju aktivnosti i procese svih sudionika.

Okvir za pozicioniranje očekivanja i mogućnosti ERP sustava bi trebao pomoći kod procjene sukladnosti onoga što kupac očekuje od implementacije ERP sustava i onoga što ponuditelj može isporučiti, uzimajući u obzir potrebe organizacije, koristeći metodike uvođenja ERP sustava i preporuke najbolje prakse uvođenja ERP sustava u visoka učilišta.

8.3. Integracijsko procesno i podatkovno sučelje ERP sustava visokih učilišta i drugih informacijskih podsustava

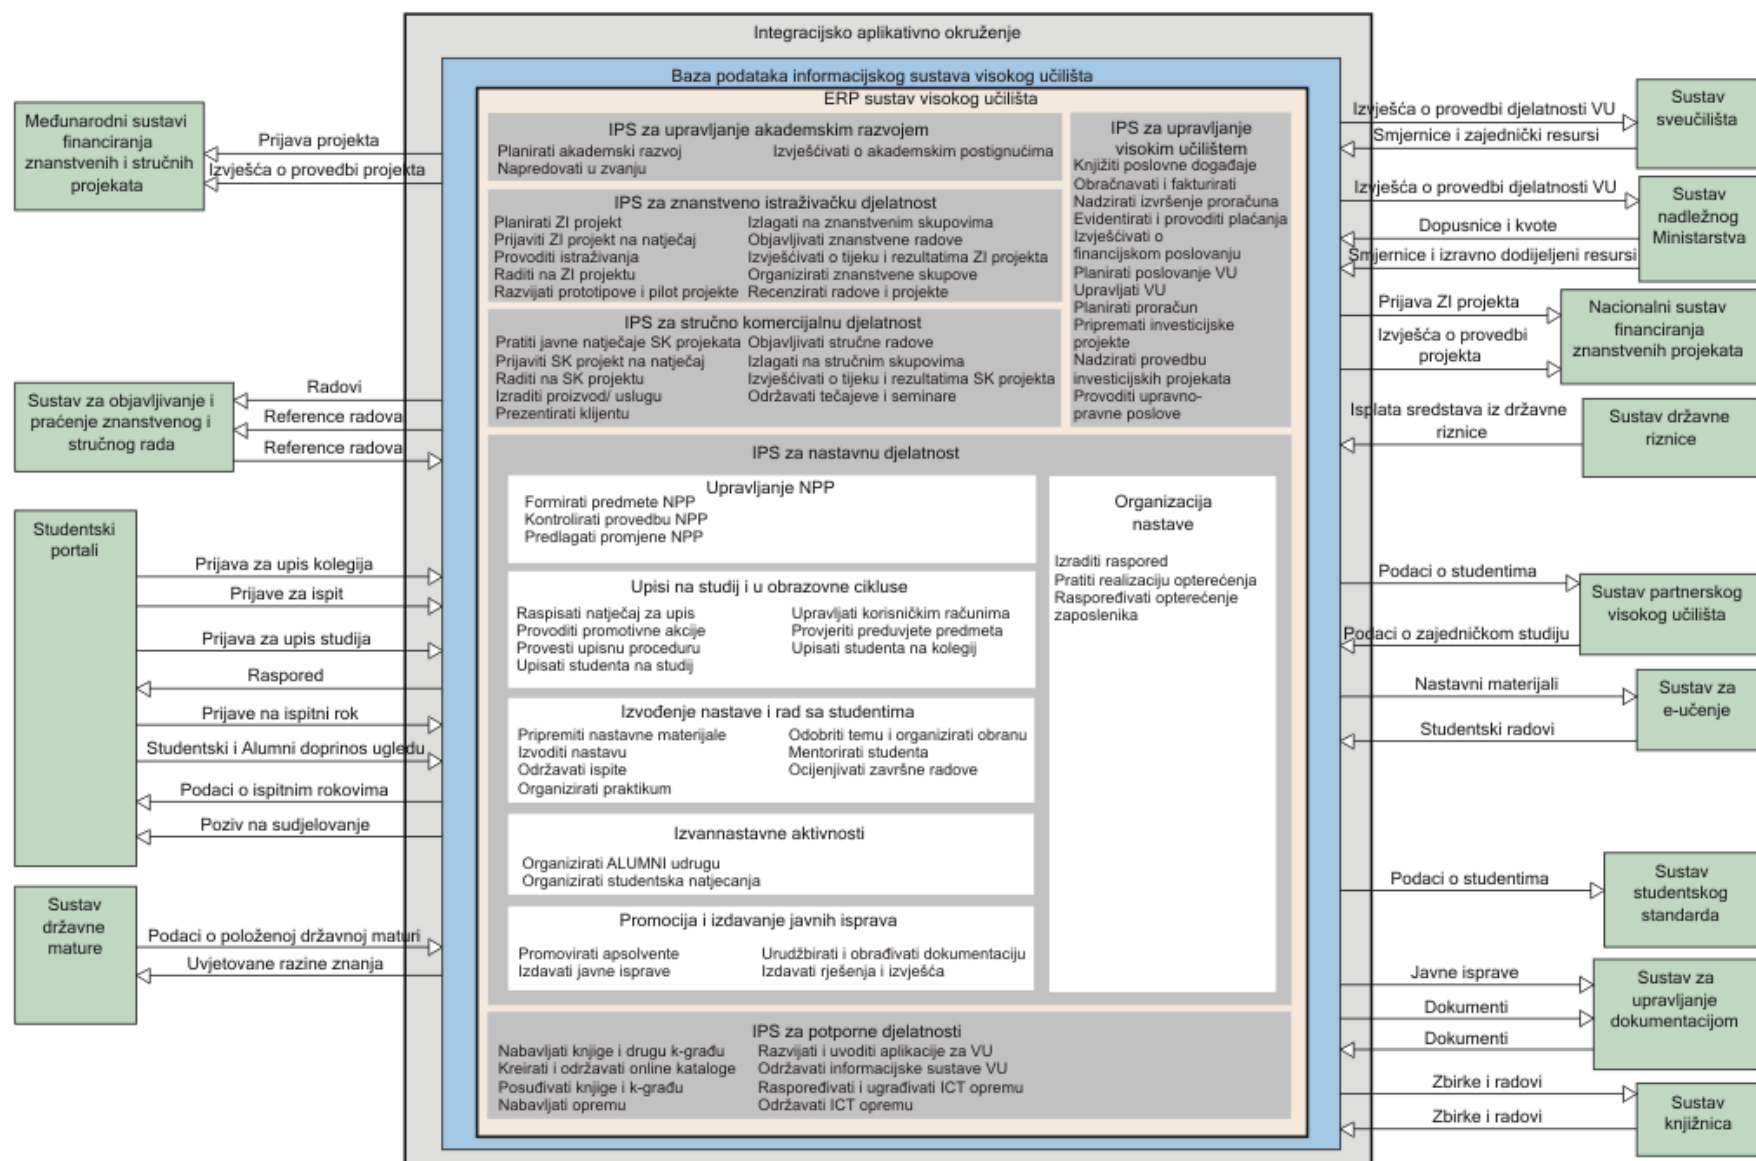
U svrhu definiranja integracijskog sučelja aplikacija ERP sustava i aplikacija postojećih informacijskih (pod)sustava visokih učilišta treba definirati način realizacije informacijskog sustava visokog učilišta. Kompletna relacijska baza podataka treba fizički biti smještena na središnjem podatkovnom serveru visokog učilišta. To znači da će cijeli sustav biti centraliziran pri čemu će se oslanjati na infrastrukturu lokalne mreže odnosno intraneta. Cjelokupni aplikativni sustav treba biti razvijen na Internet tehnologijama kako bi se osigurala jednostavna dostupnost i administracija. Predložena struktura informacijskog sustava visokih učilišta iz poglavlja 6 sugerira komponentnu arhitekturu aplikacija. Komponente mogu biti realizirane različitim tehnologijama, a njihova sučelja moraju omogućavati integraciju aplikacija. Modularnost sustava koji se razvija pomoću povezanih komponenti nadalje omogućava faznu implementaciju komponenti IS-a, implementaciju modula s obzirom na prioritete, optimizaciju i redizajn parcijalnih skupova srodnih procesa bez narušavanja osnovne funkcionalnosti IS-a.

Arhitektura baze podataka mora omogućavati interoperabilnost različitih sudionika procesa visokih učilišta u umreženom okružju. Integracija aplikacija i interoperabilnost

moraju biti usredotočena na procese, a zatim i na korisnike IS-a. Aplikacije koje omogućavaju rad s podacima baze podataka visokog učilišta i aplikacije drugih postojećih informacijskih (pod)sustava moraju biti integrirane u jednu funkcionalnu cjelinu koja će podržavati izvođenje procesa u cjelini, umjesto izvođenja pojedinačnih poslova za koje su odgovorni pojedinačni korisnici.

Na slici 8.4. je prikaz integracijskog procesnog i podatkovnog sučelja ERP sustava visokih učilišta i drugih informacijskih pod(sustava). Na prikazu je dana arhitektura ERP sustava za visoka učilišta s popisom funkcionalnosti koje proizlaze iz procesa visokih učilišta i podatkovnih tokova koji predstavljaju skupove podataka koji se razmjenjuju s informacijskim podsustavima izvan osnovne strukture ERP sustava.

ERP sustav obuhvaća aplikacijske komponente namijenjen potpori informacijskih podsustava iz poglavlja 6 i njihovih procesa. Aplikacije rade nad podacima baze podataka informacijskog sustava visokog učilišta. Podaci iz baze podataka se pomoću integracijskog aplikativnog okruženja razmjenjuju ili dijele s drugim organizacijama, odnosno njihovim informacijskim sustavima prema dogovorenim razinama usluge razmjene podataka (*engl. SLA, Service Level Agreement*). Osnovni sadržaji koji se razmjenjuju ili dijele su prikazani strelicama.



Slika 8.4.: Arhitektura ERP sustava visokih učilišta s popisom funkcionalnosti i vezama prema drugim informacijskim podsustavima

Interna kohezija aplikacijskih komponenata ERP sustava i drugih aplikacija (kao što su sustav za e-učenje, sustavi za upravljanje dokumentacijom i slično) mora biti realizirana tako da su korisnicima IS-a dostupne sve funkcionalnosti za koje korisnik ima ovlaštenje, pristupa preko SSO (skraćeno od engl. termina *Single Sign On*), polazišne pristupne aplikacije ili Web portala. U slučaju implementacije pristupa podacima preko web portala, na strani klijenta biti će dovoljan Web pretraživač za pristup aplikacijama. Prednost pristupa pomoću web portala ujedno olakšava i upravljanje licencama i verzijama aplikacija, jer se ažuriranje može obaviti u pozadinskom načinu rada. Međutim, činjenica da se dio poslova vezanih uz integraciju funkcionalnosti može obavljati u pozadinskom načinu rada, ne smije narušavati transparentnost koja se očituje kroz jasne procedure korištenja podataka ERP sustava unutar organizacije i od organizacije prema okruženju. Time je omogućena dostupnost podataka svima s odgovarajućim ovlaštenjem ili dogovorenom razinom pristupa podacima u skladu s poslovnim potrebama.

Neki podsustavi iz predložene arhitekture ERP-a za visoka učilišta su djelomično uvedena u visoka učilišta u RH. Pri tom se misli na Informacijski sustav visokih učilišta (skraćeno ISVU) i Integrirani poslovni informacijski sustav visokih učilišta (IPISVU).

ISVU pokriva specifične poslovne procese visokih učilišta vezane uz realizaciju poslova studentske referade vezanih uz administraciju i vođenje zapisa o studentima, kao što su upis studenata, upis predmeta, administraciju ispitnih rokova, odnosno pokriva većinu procesa obuhvaćenih elementima IPS-a za nastavnu djelatnost sa slike 8.4. Primjenom okvira za pozicioniranje mogućnosti ERP sustava sa slike 8.2. ISVU možemo definirati sa razinom horizontalne operabilnosti 2, razinom vertikalne interoperabilnosti 1, dok pokrivenost procesa ERP modulima možemo ocijeniti razinom 3.

Iako je takav sustav bio prijeko potreban visokim učilištima u RH, nedostaci tog sustava značajno utječu na razinu prihvatanja tog sustava od strane korisnika u akademskoj zajednici. Autorica disertacije nije bila uključena u razvoj tog sustava, kao niti njezini suradnici – stručnjaci za projektiranje i razvoj informacijskih sustava, pa ključne prednosti i nedostatke ISVU može dati samo iz perspektive korisnika u akademskoj zajednici.

Ključne prednosti ISVU su:

- Podržava jednu grupu specifičnih procesa visokog učilišta koji su vezani uz administraciju nastavne djelatnosti visokog učilišta.
- Standardizira izvođenje podržanih procesa na nacionalnoj razini.
- Omogućava korištenje baze podataka prema njezinom ključnom svojstvu da se podaci unose u vrijeme i na mjestu kada su ti podaci nastali, a koriste se gdje god je to potrebno (osim u vrijeme vršnog opterećenja, vidjeti nedostatak pod 3. točkom).

Ključni nedostaci ISVU su:

- Sustav još uvijek nije u potpunosti implementiran na svim visokim učilištima u RH, a razine i načini implementacije različiti u provedenim implementacijama od opsega funkcionalnosti do različitih operativnih postupaka korištenja sustava.
- Iako ime sustava daje naslutiti drugačije, ISVU se ne može smatrati informacijskim sustavom visokih učilišta jer ne podržava sve procese visokih učilišta.
- Arhitektura sustava je zatvorena i ne dopušta ikakvu dogradnju ili intervenciju u aplikacijskom dijelu sustava od strane stručnih korisnika. Jedina razina intervencije koja je dopuštena, a koja se može shvatiti kao korisnička prilagodba aplikacije je promjena izgleda ekrana, što bilo kojem naprednom korisniku nije niti najmanje prihvatljivo.
- Intervencije nadogradnje funkcionalnosti sustava nisu obvezujuće aktivnosti za održavatelja programske podrške, što za naprednije korisnike predstavlja dodatni faktor nezadovoljstva.
- Vršno opterećenje koje je uzeto u obzir kod projektiranja sustava ne odgovara stvarnom vršnom opterećenju za vrijeme ispitnih rokova i upisa predmeta na početku semestra. Iz tog razloga se događaju zastoji u radu koji nisu organizacijski prihvatljivi.
- Zbog prednosti naveden pod 3. točkom smanjio se je opseg rada studentske referade, ali je istovremeno isto dio administracije ispita prebačen na nastavno

osoblje, što smanjuje njihovo raspoloživo vrijeme za nastavni i znanstveno istraživački rad.

Do razvoja novog cjelovitog ERP sustava visokih učilišta koji će podržavati sve procese visokih učilišta, ISVU-om podržani procesi IPS-a za nastavnu djelatnost odvijati će se primjereno ulaganju investitora, prihvatljivo.

Drugi informacijski sustav koji podržava dio procesa visokih učilišta sa slike 8.4. je IPISVU. Ovaj sustav bi trebao podržavati neke procese računovodstva, upravljanja ljudskim potencijalima, upravljanja projektima, upravljanja prostorom i održavanja, upravljanja spisima, nabavom i materijalnim knjigovodstvom. Sustav je zamišljen tako da je omogućeno povezivanje s ISVU te informacijskim sustavom za upravljanje sredstvima iz državne riznice (integrirani financijski informacijski sustav, skraćeno IFIS). Primjenom okvira za pozicioniranje mogućnosti ERP sustava sa slike 8.2. IPIS možemo definirati sa razinom horizontalne operabilnosti 2, razinom vertikalne interoperabilnosti 2, dok pokrivenosti procesa ERP modulima možemo dati razinu 1.

Kako je projekt uvođenja tek prošao probnu implementaciju na jednom visokom učilištu u RH, teško je komentirati način rada s najavljenim novim sustavom, već se mogu komentirati samo planirane aktivnosti projekta uvođenja. Odnos opsega poslova koji bi bili obuhvaćeni IPISVU-om i troškova nabave i održavanja tog sustava dugoročno nije financijski održiv, pogotovo ako postoji alternativa razvoja sličnog sustava. IPISVU ne podržava niti jedan specifični proces temeljnih djelatnosti visokih učilišta, već samo omogućava (pomoću dodatno razvijenih web servisa) interno povezivanje s postojećim funkcionalnim ISVU-om. Realizacija podrške nekih procesa IPISVU-a ne odgovara organizacijskim i procesnim potrebama (npr. proces Napredovati u zvanju) niti zahtjevima za interoperabilnošću. Prednost ovog sustava je vidljiva samo za potrebe nadzora na financijskim poslovanjem visokog učilišta od strane sveučilišta unutar kojeg djeluje i nadležnog ministarstva. S obzirom na komentirana svojstva IPISVU upitna je daljnja realizacija ovog projekta do identifikacije i otklanjanja, odnosno upravljanja rizicima koji prijete uspješnoj implementaciji.

9. Zaključak

Misija i društvena uloga visokih učilišta zahtijevaju i motiviraju da visoka učilišta i njihove procese kojima ostvaruju svoju ulogu razmatramo s dva aspekta: (1) akademski aspekt, koji ukazuje na to da su visoka učilišta organizacije sa specifičnim ciljevima i načinima postizanja tih ciljeva, te na taj način visoka učilišta izdvaja kao specifične organizacije sa jedinstvenim procesima i (2) poslovni aspekt, koji podrazumijeva da se planiranje i upravljanje resursima visokih učilišta mora odvijati u skladu s tržišnim i ekonomskim načelima upravljanja, a što za ujedno znači da se neki procesi visokih učilišta odvijaju na sličan način kao i u većini poslovnih organizacija.

U drugom poglavlju rada su istraženi modeli i načini financiranja visokih učilišta radi identifikacije zahtjeva na ERP sustav namijenjen planiranju i praćenju resursa visokih učilišta. Uočen je trend smanjivanja prihoda iz nacionalnih državnih izvora, dok se istovremeno razvijaju novi izvori financiranja koji se odnose na znanstveno istraživački rad i interdisciplinarnu primjenu rezultata istraživanja u društvu i gospodarstvu. Različiti izvori financiranja imaju različite sheme financiranja. Novi izvori financiranja zahtijevaju drugačije načine upravljanja troškovima od tradicionalnih, kao što je ABC inačica praćenja troškova nazvana model potpunih troškova visokog učilišta. Da bi se implementiralo praćenje svih izravnih i neizravnih troškova realizacije djelatnosti koja se financira iz određenog izvora, troškovi visokih učilišta moraju se razgraničiti na mjesta nastanka troškova te upravljati resursima kako bi ti troškovi bili u granicama financiranog iznosa. Upravljanje troškovima po mjestima troška predstavlja jedan od zahtjeva funkcionalnosti informacijskog sustava, bez kojeg je učinkovito planiranje i upravljanje resursima nezamislivo. Razlika poslovnog i javnog sektora pritom također ima utjecaj na učinkovito upravljanje resursima.

Akademski aspekt upravljanja resursima visokih učilišta usmjeren je na izvođenje aktivnosti s ciljem ostvarenja misije postojanja visokog učilišta, dok se poslovni aspekt upravljanja resursima zanemarivao u korist većeg dobra – društvene koristi. Promjene u financiranju tjeraju visoka učilišta da probude svijest o nužnosti učinkovitog upravljanja resursima kao važnog čimbenika opstanka javnih visokih učilišta u kompetitivnom okruženju u kojem jača privatni sektor visokog obrazovanja, što znači da je nužna primjena nekih metoda korporativnog upravljanja iz poslovnog sektora.

Postoji više specifičnosti sustava planiranja i upravljanja resursima visokih učilišta u RH, u odnosu na visoka učilišta u svijetu. Jedna se odnosi na činjenicu da su izdvojeni poslovi i troškovi vezani uz studentski standard u organizacije izvan visokih učilišta (konkretnije u studentske centre, prijevoz studenata i slično). Ako se izuzmu troškovi smještaja i prehrane studenata, u upravljanju troškova studentskog standarda ima mjesta za unapređenje raspodjele i preusmjerenje sredstava. Stipendiranje studenata, kao dio studentskog standarda, u načelu nije centralizirano niti vezano uz visoka učilišta kao i u većini visokih učilišta u svijetu, što dovodi do toga da se niti na razini države ne može u potpunosti procijeniti koliko se kroz stipendije ulaže u studentski standard, čime se posredno dijelom kroz školarine ulaže u visoko obrazovanje. Jedan dio stipendija se realizira iz donacija gospodarstva i to je jedini značajan primjer donacija u visokom obrazovanju. Donacije visokim učilištima u RH za financiranje osnovnih djelatnosti nikada nisu postale značajan izvor financiranja, a s obzirom na poticaje iz nacionalnih institucija to se niti u skoroj budućnosti ne može očekivati. Značaj donacija (*engl. fundraising*), te fondovi i zaklade kao izvori financiranja djelatnosti visokih učilišta u našoj zemlji nisu prepoznati, niti odgovarajuće preuzeti na javnim visokim učilištima.

Na kraju drugog poglavlja je analiziran utjecaj strukture sustava i okruženja visokih učilišta, te su definirane osnovne konture i zahtjevi na informacijski sustav visokih učilišta. Zahtjevi na informacijski sustav izvedeni su iz općeg modela funkcioniranja visokih učilišta na tri razine procesa: operativnoj, upravljačkoj i na razini odlučivanja, s obzirom na tri glavne djelatnosti visokih učilišta: (1) rad u nastavi, (2) znanstveno istraživački rad i (3) stručni rad.

U trećem poglavlju rada su metodom dekompozicije glavnih triju djelatnosti na poslove i analizom pravnih akata i pravilnika koji uređuju područje djelovanja, prepoznati osnovni procesi visokih učilišta. Popis procesa je analiziran s obzirom na životni ciklus osnovnih resursa visokih učilišta: Predmet, Nastavni plan i program, Nastavnik, Novac, Stručni doprinos, Stručnjak, Student, Znanstveni doprinos, Znanstvenik, te Tehničku infrastrukturu i opremu. Analiza je pokazala da je popis procesa kompletan jer za ključne resurse visokih učilišta postoji slijed procesa koji omogućavaju transformaciju resursa od ulaznog formata do izlaznog. Prepoznati procesi su nakon toga modelirani koristeći notaciju za modeliranje poslovnih procesa (BPMN, [13]).

Dobiveni modeli su u četvrtom poglavlju rada uspoređeni sa drugim javno dostupnim modelima procesa visokih učilišta. Dosadašnja istraživanja i modeli koji su pronađeni u dostupnim izvorima, usmjereni su na pojedinačne procese ili proizvoljno grupirane procese studentske administracije, upravljanja kadrovima i upravljanja financijama visokih učilišta te ne daju pregled nad vezama svih procesa visokih učilišta. Pronađeno je 9 javno dostupnih modela procesa, različitih formi, iz različitih izvora: neki su nastali na visokim učilištima, neki su predstavljeni od dobavljača gotovih informacijskih sustava, dok za neke nije poznato s kojom svrhom su izrađeni, ali su prikazani jer pokazuju različite pristupe i razine detaljizacije izrade modela procesa. Istraživanje pokazuje da ne postoje modeli procesa visokih učilišta koji bi bili izrađeni nekom suvremenom metodom modeliranja procesa i koji bi pružali cjelovit prikaz akademskih i poslovnih procesa visokih učilišta. S obzirom na navedeno, jasno je da ne postoje niti referentni modeli procesa visokih učilišta koji bi predstavljali najbolju praksu planiranja i upravljanja resursima visokih učilišta, pružali mogućnost analize ključnih podataka koje procesi visokih učilišta kreiraju i koriste, ili služili kao predložak za razvoj ERP sustava. Zato je istraženo je li moguće napraviti referentni model planiranja i upravljanja resursima koji je specifičan za visoka učilišta, s naglaskom na znanstveno-istraživačku i nastavnu komponentu. Istraživanje je provedeno tako da je izrađen model akademskih i poslovnih procesa visokih učilišta te je taj model uspoređen sa pronađenim modelima. Za usporedbu modela procesa su definirani kriteriji usporedbe koji se odnose na sadržaj, format i opseg modela, a izvedeni iz karakteristika referentnih modela prema Fettke et.al. [31]. Zaključeno je da se predloženi model akademskih i poslovnih procesa može koristiti za pregled, planiranje, analizu i upravljanje resursima u visokim učilištima.

Model akademskih i poslovnih procesa visokih učilišta prikazuje procese i podatkovne sadržaje koje procesi kreiraju i koriste. Proces organizacije diktiraju koje funkcionalnosti treba imati aplikacija informacijskog sustava kako bi optimalno podržavala izvođenje procesa. Aplikacije informacijskog sustava pri tom koriste podatke koji su na strukturiran način pohranjeni u odgovarajućoj formi u bazi podatka informacijskog sustava. Zato je uz izradu referentnog model procesa planiranja i upravljanja resursima visokih učilišta važno analizirati i strukturu i semantiku podataka

koje procesi generiraju ili koriste. Odnosi procesa i podatkovnih sadržaja iz modela procesa su prevedeni u matricu procesa i klasa podataka, pri čemu su podatkovni sadržaji prevedeni u klase podataka. Matrica procesa i klasa podataka prikazuje koje klase podataka procesi generiraju i koriste. Temeljem empirijskog grupiranja procesa prema fazama životnog ciklusa osnovnih resursa i analize afiniteta procesa s obzirom na klase podataka, provedeno je grupiranje procesa. Srodni procesi u grupi određuju koje funkcionalnosti informacijski podsustavi informacijskog sustava za planiranje i praćenje resursima visokih učilišta trebaju imati. Za predložene informacijske podsustave je provedena analiza preklapanja informacijskih podsustava sa modulima koji čine osnovnu strukturu komercijalnih ERP sustava za visoka učilišta. Podaci o modulima komercijalnih ERP sustava su prikupljeni preko službenih web stranica proizvođača ERP sustava i drugih dostupnih izvora, kao što su izvješća stručnih organizacija koje prate tržište ERP sustava (npr. Gartner, IDC) te izvješća tehnički usmjerenih konzultantskih organizacija. Nakon toga su uspoređene prepoznate standardizirane funkcionalnosti klasičnih ERP alata i specifične funkcionalnosti ERP sustava za visoka učilišta pomoću usporedbe osnovnih koncepata ERP sustava. Osnovni koncepti ERP sustava visokih učilišta su izvedeni iz klasa podataka i modelirani kao objekti logičkog podatkovnog modela u šestom poglavlju. Model podataka je nužan za istraživanje druge hipoteze o postojanju sličnosti koncepata ERP sustava, što je razrađeno u sedmom poglavlju rada. Cilj je bio potvrda ili opovrgavanje hipoteze da se sustavi planiranja i upravljanja resursima visokih učilišta strukturno i semantički temelje na osnovnim konceptima ERP sustava, ali istovremeno imaju i vlastite koncepte koji ih u ontološkom smislu čine posebnom klasom takvih sustava. S obzirom da su osnovni koncepti ERP sustava prikazani grafičkim modelima, odnosno dijagramima, u istraživanju je za dokazivanje ove hipoteze primijenjena teorija grafova. Analiza je pokazala koje koncepte dijele ERP sustavi visokih učilišta s ERP sustavom proizvodnog poduzeća kao odabranog tipa organizacije. Usporedbom osnovnih koncepata pronađen je podskup koncepata koji su zajednički ERP sustavima visokih učilišta i ERP sustava proizvodnog poduzeća, čime je potvrđen prvi dio testirane hipoteze. Koncepti tog podskupa mogu se smatrati obrascem (ili predloškom) objekata s vezama koje mogu biti primijenjene u različitim ERP sustavima. Kako u podskup zajedničkih koncepata nisu ušli svi koncepti ERP sustava

visokih učilišta, zaključeno da je ERP sustavi visokih učilišta posjeduju vlastite koncepte koji ih čine posebnom klasom ERP sustava. Time je potvrđena razmatrana hipoteza.

Metodike izgradnje ERP sustava iz petog poglavlja rada su uzete u obzir kod određivanja uvjeta i oblika implementacije ERP sustava uz poštivanje načela interoperabilnosti i integracije (poglavljje osmo). Na temelju dostupnih izvora, istražene su četiri metodike, a zaključeno je da sve metodike propisuju analizu poslovnog sustava kao polazišnu osnovu za utvrđivanje karakteristika, strukture i arhitekture novog IS-a. Iz ostalih koraka metodika, na temelju analize karakteristika definiranih relevantnom normom ISO 9126 [39] za kvalitetu softvera, karakteristika predloženih kod odabira optimalnog ERP sustava od autora Liang i Lien [53] i Botella et.al. [7], karakteristika dobrih ERP sustava definiranih od autora Singh i Wesson [82], mogu se izvesti sljedeće značajke dobrog ERP sustava visokih učilišta:

- Modularnost: struktura modula sustava planiranja i upravljanje resursima visokih učilišta je predložena u sedmom poglavlju u sklopu definiranja integracijskog sučelja. Moduli su izvedeni na temelju analize BSP matrice a formirani su tako da omogućavaju optimalnu potporu srodnim procesima visokih učilišta funkcionalnostima koje moduli trebaju imati i skupom podataka nad kojima se aplikacije izvode. Modularnost nadalje omogućava faznu implementaciju, implementaciju modula s obzirom na prioritete, optimizaciju i redizajn parcijalnih skupova srodnih procesa bez narušavanja funkcionalnosti cijelog IS-a.
- Maksimalna povezanost modula ERP sustava i ERP sustava s modulima drugih informacijskih (pod)sustava (poput sustava za e-učenje, eksternih sustava za praćenje znanstvenog rada, informacijskog sustava studentskog centra, i sl.).
- Vertikalna interoperabilnost je sposobnost programskog alata da osigura izvođenje cjelokupnog procesa kroz različite razine izvođenja, upravljanja i odlučivanja bez obzira na organizacijska ograničenja (dakle unutar vertikalne industrije visokog učilišta).

- Horizontalna interoperabilnost kao sposobnost programskog alata da osigura izvođenje cjelokupnog slijeda procesa na istoj razini izvođenja, upravljanja ili odlučivanja bez obzira na organizacijska ograničenja.
- Cjelovitost s obzirom na procese lanca generiranja novih vrijednosti izvedenog iz vizije, misije i strateških ciljeva visokog učilišta.
- Transparentnost koja se očituje kroz jasne procedure korištenja ERP sustava unutar organizacije i od organizacije prema okruženju.
- Dostupnost, realizirana pomoću portala, društvenih mreža i sustava poruka temeljenih na suvremenim komunikacijskim tehnologijama.
- Funkcionalnost ERP sustava je sposobnost alata da izvede očekivani skup funkcija koje moraju biti realizirane prema zahtjevima iz poslovnih potreba organizacije.
- Pouzdanost ERP sustava koja se očituje kao sposobnost alata da pruži očekivanu razinu funkcionalnosti u određenim uvjetima kroz zadano vrijeme.
- Korisnost je svojstvo ERP sustava koje iskazuje kako funkcionalnost alata odgovara očekivanjima korisnika u izvedbi njihovih poslovnih procesa, što je vrlo važna značajka jer sama funkcionalna aplikacija ne mora svakom korisniku biti korisna.
- Efikasnost je značajka koja svojstvo alata da bude funkcionalan i koristan uz minimalan utrošak resursa potrebnih za rad ERP sustava.
- Održivost je sposobnost alata da uspije zadržati očekivanu razinu funkcionalnosti, korisnosti i efikasnosti kod provođenja korektivnih mjera u aplikaciji (ovo svojstvo se može usporediti sa svojstvom popravljivosti proizvoda, npr. uređaja, u proizvodnoj industriji).
- Prenosivost je svojstvo zadržavanja razine funkcionalnosti, korisnosti i efikasnosti u promjenjivom okruženju.

Zaključno se može reći da su radom postignuti ciljevi koji se odnose na određivanje primjenjivosti osnovnih koncepata i strukture ERP sustava u specifičnom području planiranja i upravljanja resursima visokih učilišta, izradu referentnog modela procesa

planiranja i upravljanja resursima visokih učilišta i definiranje integracijskog procesnog i podatkovnog sučelja i određivanje uvjeta interoperabilnosti ERP sustava visokih učilišta i drugih informacijskih podsustava. Dokazane su hipoteze da se sustavi planiranja i upravljanja resursima visokih učilišta strukturno i semantički temelje na osnovnim konceptima ERP sustava, ali istovremeno imaju i vlastite koncepte koji ih u ontološkom smislu čine posebnom klasom takvih sustava i da je moguće je napraviti referentni model procesa planiranja i upravljanja resursima koji je specifičan za visoka učilišta, s naglaskom na znanstveno-istraživačku i nastavnu komponentu.

U daljnjim istraživanjima bi bilo vrijedno istražiti realne varijante pojedinačnih procesa iz predloženog modela procesa planiranja i upravljanja resursima visokih učilišta u svrhu operativne primjena modela. Mogući smjer istraživanja je modeliranje različitih verzija modela procesa koje proizlaze iz poslovnih vremenskih, kadrovskih i drugih ograničenja (npr. izvođenje nastave u semestrima ili kraćim koncentriranim terminima) radi simuliranja troškova i učinaka na preglednom modelu.

U radu je definiran algoritam određivanja semantičke i strukturne sličnosti modela podataka ERP sustava. To je važno jer su strukturirani podaci osnova za primjenu aplikacija ERP sustava koje podržavaju poslovne procese. Ako postoji sličnost strukture podataka ERP sustava onda se može pretpostaviti da postoji i određena sličnost aplikacija i programskih procedura koje podatke koriste. Ako krenemo od pretpostavke autora Zhai i Zang [99], da su osnovne aplikacijske komponente ERP sustava za diskretnu proizvodnju 1) planiranje potreba i kapaciteta, 2) planiranje proizvodnje, 3) nabava, 4) proizvodnja i 5) prodaja, postavlja se pitanje mogu li se te aplikacije prepoznati u drugim ERP sustavima (npr. u ERP sustavima za visoka učilišta)? Stoga bi u budućim istraživanjima bilo korisno istražiti sličnosti aplikacija različitih ERP sustava, odnosno istražiti sličnost programskih procedura obrade semantički i strukturno sličnih podataka.

Referentni model procesa planiranja i upravljanja resursima koji je predložen u radu, specifičan je za visoka učilišta, a ima naglasak na znanstveno istraživačku i nastavnu komponentu. Model prikazuje visoko učilište kao organizaciju koja ima vlastite specifične akademske procese koji se ne mogu prepoznati u drugim djelatnostima i poslovne procese koji se osiguravaju rad visokog učilišta kao organiziranog poslovnog

subjekta. Specifični akademski procesi koji određuju sustav planiranja i upravljanja ključnim resursima visokih učilišta ukazuju na to da ERP sustavi visokih učilišta mogu imati vlastite jedinstvene koncepte koji nisu prisutni u drugim ERP sustavima.

Osnovni koncepti ERP sustava, koji su prvotno bili namijenjeni profitno orijentiranoj proizvodnji, implementirani su i u sustavima planiranja i upravljanja resursima visokih učilišta. Iako je analiza sličnosti koncepata pokazala da **ERP sustavi visokih učilišta dijele neke zajedničke koncepte s drugim ERP sustavima**, što je posljedica evolucije i recikliranja postojećih ERP sustava, ista analiza je pokazala da **imaju i vlastite jedinstvene koncepte**. To vodi do zaključka da sustavi planiranja i upravljanja resursima visokim učilištima nisu podvrsta već postojećih ERP sustava, već da su u ontološkom smislu posebna klasa sustava planiranja i upravljanja resursima.

BIBLIOGRAFIJA

- [1] Ahituv, N., Neumann, S., Zviran, M., A System development methodology for ERP systems, *Journal of Computer Information Systems*, 42 (3): 56-67, 2002.
- [2] Anonymous, ERP: Gartnerovi savjeti dobavljačima i korisnicima - Gartner globalno, *Infotrend*, br. 172, srpanj 2009.
- [3] Australian Government, Department of Innovation, Industry, Science, and Research Publications: Higher education research Data collection Specifications for the collection of 2010 data, dostupno na <http://www.innovation.gov.au/Research/ResearchBlockGrants/Pages/HigherEducationResearchDataCollection.aspx> (28.03.2011.)
- [4] Bajo, A., *Financiranje visokog obrazovanja i financijska potpora studentima*, Institut za razvoj obrazovanja, Prezentacije simpozija „Uloga ljudskog prava na obrazovanje u demokratizaciji visokog obrazovanja u Hrvatskoj“, 2006., dostupno na http://www.iro.hr/userdocs/File/pno2006/3_bajo.pdf (11.12.2010.)
- [5] Blocher, E.J., Stout, D.E., Cokins, G., Chen, K.H.: *Cost Management: A Strategic Emphasis*, 4th edition, McGraw-Hill/Irwin, New York, 2008.
- [6] Bologna, R., Bologna, A., Sabau, G., Success Factors for Higher Education ERPs, *Proceedings of the 2009 International Conference on Computer Technology and Development - (ICCTD '09)*, Vol. 1:28-32, IEEE Computer Society, Washington, DC, USA,
- [7] Botella, P., Illa, X.B., Carvallo, J.P., Franch, X., Pastor, J.A., Quer, C., Towards a Quality Model for the Selection of ERP Systems, *Proceedings of Component-Based Software Quality*, Springer, Vol. 2693: 225-245, 2003.
- [8] Bruijin, H., Performance measurement in the public sector: strategies to cope with the risks of performance measurement, *The International Journal of Public Sector Management*, 15(7): 578-594, 2002.
- [9] Brumec, J., Mjerenje uspješnosti organizacije metodom Balanced Scorecard, Sedmi financijski forum, Zagreb 21.-23. svibnja 2002. Infoforum d.o.o., Zagreb, 2002.
- [10] Brumec, J., Dobrović, Ž., Tomičić, M., The model of the document management system in the public sector, *Journal of information and organizational sciences*. 30 (1): 29-46, 2006.
- [11] Brumec, J., Vrček, N., Strategic Planning of Information Systems (SPIS) - A Survey of Methodology, *Journal of Computing and Information Technology – CIT*, 10(3): 225-231, 2002.
- [12] Bruno, K., Welz, L., Vrana, B., Practical Process Engineering for Higher Education, CAUSE 98 Conference Proceedings, Seattle, Washington, December 8-11, 1998., On-line proceedings dostupno na: <http://www.educause.edu/ir/library/html/cnc9864/cnc9864.html>, (02.01.2010.)
- [13] Business Process Model And Notation Version 2.0, OMG Final Adopted Specification, 2011, dostupno na <http://www.omg.org/spec/BPMN/2.0/> (02.03.2011)
- [14] Charles Sturt University. *CSU Workplace Productivity Program, A Structured Approach to Workplace Productivity, Renewal and Reform*. Dostupno na www.csu.edu.au/special/wpp (02.03.2011)

- [15] **Cherednichenko, O., Kuklenko, D., Zlatkin, S., Coordinating Higher Education as an e-Government Initiative, *Information Systems Technology and its Applications, 5th International Conference ISTA 2006, 27-38, Klagenfurt, Austria, 2006.***
- [16] Divjak, B., Lovrenčić, A., *Diskretna matematika s teorijom grafova*, TIVA-FOI, Varaždin, 2005.
- [17] Divjak, B., Nastavni materijali za predmet Odabrana poglavlja matematike, Sustav za e-učenje na FOI, 2010.
- [18] Dobrović, Ž., Tomičić, M., Vrček, N., Towards An Effective e-Government: Implementation of a Balanced Scorecard in the Public Sector, *Intellectual Economics*, 1(3): 7-17, 2008.
- [19] Dokumentacija projekta Financiranje visokih učilišta u RH - slučaj Sveučilišta u Zagrebu - Sažetak projekta, (voditelj prof. dr.sc. Ivan Lovrinović), Ekonomski fakultet. Zagreb, 2006.
- [20] Education strategies. www.edustrat.com/vendors.html (01.03.2011.)
- [21] ENQA Publications: Regulations of the european association for quality assurance in higher education preuzeto sa <http://www.enqa.eu/index.lasso> (28.08.2009.)
- [22] *Enterprise Resource Planning Evaluation Center*, <http://erp.technologyevaluation.com> (03.02.2010.)
- [23] Esteves, J., Bohórquez, V., An Updated ERP Systems Annotated Bibliography: 2001-2005. *Communications of the Association for Information Systems (CAIS)*, Vol. 19, Article 18, 2007.
- [24] Esteves, J., Towards a Stakeholder Analysis of an ERP Adoption in a Higher Education, *1st international workshop on information, knowledge and management: Re-assessing the value of ICT in public and private organizations*, Bologna, Italy, 2004.
- [25] Esteves, J., Pastor, J., Enterprise resource planning systems Research: an annotated bibliography, *Communications of the Association for Information Systems (CAIS)*, 7(8): 1-52, 2001.
- [26] *European Interoperability Framework for European Public Services*, <http://ec.europa.eu/idabc/> (03.02.2010.)
- [27] *European University Association Publications: Financially Sustainable Universities: Towards full costing in european universities*, European University Association, Brussels, Belgium, 2008., dostupno na <http://www.eua.be/Publications.aspx> (01.04.2011)
- [28] *European University Association Publications: Sursock, A., Smidt, H., Trends 2010: A decade of change in European Higher Education*, European University Association, Brussels, Belgium, 2010., dostupno na <http://www.eua.be/Publications.aspx> (01.04.2011)
- [29] *Eurydice Publications: Higher Education Governance in Europe. Policies, Structures, funding and Academic Staff*, Eurydice, Brussels, Belgium, 2008., dostupno na http://eacea.ec.europa.eu/education/eurydice/thematic_studies_en.php (01.04.2011)
- [30] Federal Enterprise Architecture (FEA). <http://www.whitehouse.gov/omb/e-gov/fea/> (01.02.2011.)

- [31] Fettke, P., Loos, P., Zwicker, J., Business Process Reference Models: Survey and Classification, *Proceeding of the Workshop on Business Process Reference Models BPRM 2005*, 1-15, Nancy, France, 2005.
- [32] Frantz, P., Southerland, A., Johnson, J., ERP Software Implementation Best Practices, *Educause quarterly*, 25(4): 38-45, 2002.
- [33] Gartner. www.gartner.com (04.03.2011.)
- [34] Higher Education Funding Council for England Publications: The higher education workforce framework 2010: Overview report, HEFCE, 2010., dostupno na <http://www.hefce.ac.uk/pubs/hefce/2010/> (01.04.2011.)
- [35] Higher education Institution - Florida Atlantic University. <http://www.fau.edu/financial/Best-Practices/index.php> (20.10.2010.)
- [36] Hunjak, T., *Izvanproračunski izvori financiranja sveučilišne djelatnosti*, Financiranje hrvatskih sveučilišta, Tempus Fimacrou, Dubrovnik, 2005., dostupno na www.unizg.hr/tempusprojects/cro4Bologna/hunjakdubrcet.ppt. (20.10.2010.)
- [37] Hunjak, T., *Okvir za izradu modela distribucije proračuna Sveučilišta u Zagrebu*, Dokumentacija projekta Financiranje visokih učilišta u RH - slučaj Sveučilišta u Zagrebu (voditelj prof. dr.sc. Ivan Lovrinović), Ekonomski fakultet . Zagreb, 2006., str. 97-104
- [38] International Data Corporation (IDC). www.idc.com, http://www.idc-adriatics.com/?showproduct=38243&content_lang=HR (02.03.2011.)
- [39] ISO/IEC 9126:2001, Software engineering -- Product quality.
- [40] Jakupović, A., Pavlić, M., Fertalj, K., Analysis and Classification of ERP Producers by Business Operations, *Journal of computing and information technology (1330-1136)*, 17(3): 239-258, 2009.
- [41] Jenzabar. www.jenzabar.com (01.03.2011.)
- [42] JISC. *Dijagram dekompozicije akademskih procesa prema studentima organizacije JISC*. Dostupno na: <http://www.jiscinfonet.ac.uk/InfoKits/process-review/printable-version.pdf> (11.11.2010.)
- [43] JISC. Donaghy, M., *CRM Processes: Self Analysis Tools*. Dostupno na: <http://jisc.cetis.ac.uk/crm-tools/documents/process-maps-report.pdf> (02.03.2011)
- [44] JISC. Model procesa Odabira predmeta organizacije. Dostupno na: <http://www.jiscinfonet.ac.uk/InfoKits/process-review/printable-version.pdf> (11.11.2010.)
- [45] JISC. Review of the Joint Information Systems Committee. Dostupno na: <http://www.jiscinfonet.ac.uk/InfoKits/process-review/printable-version.pdf> (11.03.2011.)
- [46] Kaplan R.S., Norton, D.P., The Balanced Scorecard - Measures That Drive Performance, *Harvard business review*, 70(1):71-79, January-February 1992.,
- [47] Kashyap, V., Sheth A., Semantic and Schematic Similarities between Database Objects A Context-based approach. *The VLDB Journal — The International Journal on Very Large Data Bases*, 5(4): 276-304, 1996.
- [48] Keet, C.M., A formal comparison of conceptual data modeling languages, *13th International Workshop on Exploring Modeling Methods in Systems Analysis and Design (EMMSAD'08)*, Vol-337, 25-39, Montpellier, France, 2008.

- [49] Kettunen, J., Kantola, I., Management information system based on the balanced scorecard, *Campus-Wide Information Systems*, 22(5): 263 – 274, 2005.
- [50] King, P., The promise and Performance of Enterprise Systems in Higher Education, Respondent Summary, *ECAR Respondent Summary*, 2002., preuzeto sa <http://net.educause.edu/ir/library/pdf/ERS0204/rs/ers0204w.pdf>, (28.08.2009.)
- [51] Laguna, M., Marklund, J., *Business Process Modeling, Simulation, and Design*, Pearson Prentice Hall, New Jersey, 2005.
- [52] Li, L., Hosking, J., Grundy, J., Visual Modelling of Complex Business Processes with Trees, Overlays and Distortion-based Displays, VLHCC '07 Proceedings of the IEEE Symposium on Visual Languages and Human-Centric Computing, str. 137-144, IEEE Computer Society Washington, DC, USA, 2007.
- [53] Liang, S., Lien, C., Selecting the Optimal ERP Software by Combining the ISO 9126 Standard and Fuzzy AHP Approach, *Contemporary Management Research*, 3(1): 23-44, 2007.
- [54] Mammar, A., Laleau, R., From a B formal specification to an executable code: application to the relational database domain. *Information and Software Technology*, 48(4): 253-279, 2006.
- [55] Marnewick, C., Labuschagne, L.: A conceptual model for enterprise resource planning (ERP), *Information Management & Computer Security*, 13(2): 144-155, 2005.
- [56] Mendling, J., Van der Aalst, W., Van Dongen, B., Verbeek, E.: Errors in the SAP Reference Model, In: *BPTrends*, June 2006., preuzeto sa <http://www.bptrends.com/publicationfiles/06-06-WP-ErrorsInSAPRefModel-Mendling-et-al.pdf> (20.07.2009.)
- [57] Merwe, A., Kotze, P., A systematic approach for the identification of process reference models, *Proceeding of the IASTED International Conference on Software Engineering, IASTED 2009*, 75-80, Innsbruck, Austria, 2009.
- [58] Microsoft. www.microsoft.com ((01.03.2011.))
- [59] Monk, E., Wagner, B., *Concepts in Enterprise Resource Planning*, 3rd.ed., Course Technology Cengage Learning, Boston, Massachusetts, 2009.
- [60] Narodne novine: Pravilnik o financijskom izvještavanju u proračunskom računovodstvu, NN 032/2011.
- [61] Narodne novine: Pravilnik o proračunskom računovodstvu i Računskom planu, NN 114/2010.
- [62] Narodne novine: Pravilnik o utvrđivanju korisnika proračuna i o vođenju registra korisnika proračuna, NN 80/2004.
- [63] Narodne novine: *Zakon o proračunu*, NN 87/2008., NN 96/2003., NN 92/1994.
- [64] Narodne novine: *Zakon o visokim učilištima (pročišćeni tekst)*, NN, 59/1996., izmjene i dopune: NN 129/2000., NN 78/2003.
- [65] Narodne novine: *Zakon o znanstvenoj djelatnosti i visokom obrazovanju*, NN 123/2003., izmjene i dopune: NN 46/2007., NN 174/2004., NN 105/2004., NN 198/2003.
- [66] Noreen, E.W., Brewe, P.C., Garrison, R.H., *Managerial Accounting for managers*, McGraw-Hill/Irwin, New York, 2008.
- [67] *OECD Publications*. Duke, C., Hasan A., Cappon P., Meissner W., Metcalf H., Thornhill D., *OECD reviews of tertiary education: Croatia*, Paris, 2008.

- [68] O'Leary, D., Enterprise Resource Planning Systems, Cambridge University Press, Cambridge, 2000.
- [69] Oracle. www.oracle.com (01.03.2011.)
- [70] Oxford Brookes University, BSc (Hons) in Applied Accounting and Research and Analysis Project Information pack, April 2009, dostupno na <http://www.accaglobal.com/documents/bscinfopack.pdf>, (15.12.2010.)
- [71] Parr, A.N., G. Shanks, A Taxonomy of ERP Implementation Approaches, *Proceedings of the 33rd Hawaii International Conference on System Sciences*, 1-10, Hawaii, 2000.
- [72] Perry, J.L., Rainey H.G., The Public-Private Distinction in Organization Theory: A Critique and Research Strategy, *The Academy of Management Review*, 13(2): 182-201, 1988.
- [73] Pilho, K., E-model: event-based graph data model theory and Implementation, PhD Thesis, Georgia Institute of Technology, Atlanta Georgia, USA, 2009.
- [74] Pollock, N., Cornford, J.: ERP systems and the university as a "unique" organisation, *Information Technology and people*, 17(1): 31-52, 2004.
- [75] Pollock, N.: The „self-service“ Student: Building Enterprise wide Systems into Universities, *Prometheus*, 21(1): 101-119, 2003.
- [76] Porter, M. *Competitive Advantage Creating and sustaining*. The Free Press, New York, 1985.
- [77] Pupius, M., Sheffield Hallam University Process Model v6, Centre for Integral Excellence, Sheffield Hallam University Quality and Excellence in Higher Education; preuzeto sa http://www.kodolanyi.hu/images/tartalom/File/hefop/quality2_mike_pupius.pdf, (17.12.2010.)
- [78] Rabaa'i, A. A., Wasana, B., Guy G.G., Enterprise systems in universities: a teaching case, *Proceedings of the Sixteenth Americas Conference on Information Systems*, [AIS Electronic Library, AMCIS 2010, paper 171], Lima, Peru, 2010.
- [79] Rabaa'i, A.A., Identifying critical success factors of ERP Systems at the higher education sector, In *ISIICT 200 : Third International Symposium on Innovation in Information & Communication Technology*, Philadelphia University, Amman, Jordan, 2009.
- [80] Rosemann, M., Shanks, G., Extension and Configuration of Reference Models for Enterprise Resource Planning Systems, *Proceedings of the 12th Australasian Conference on Information Systems-ACIS 2001*, 537-546Coffs Harbour, Australia, 2001.
- [81] Ruskov P., Ruskov A., Academic Education Chain Operation Model, *2nd Tencompetence Workshop*, Manchester G-Mex, UK, January, 2007.
- [82] Singh, A., Wesson, J., Evaluation criteria for assessing the usability of ERP systems, *Proceedings of the 2009 Annual Research Conference of the South African Institute of Computer Scientists and Information Technologists (SAICSIT '09)*, 87-95, New York, NY, USA, 2009.
- [83] Song, W.W.; Johannesson, P.; Bubenko Jr. J.A. Semantic Similarity Relations in Shema Integration, *Lecture Notes in Computer Science*, Vol.645 p.97-120, 1992
- [84] Strahonja, V., Nastavni materijali za predmet Referentni modeli i ERP sustavi, Sustav za e-učenje na FOI, 2010.
- [85] Sungard ERP. <http://www.sungardhe.com/>

- [86] Systems, Applications, and Products in Data Processing (SAP). www.sap.com (01.03.2011.)
- [87] The Open Group Architecture Framework. <http://www.opengroup.org/togaf/>
- [88] The Southern Association of College and University Business Officers (SACUBO). www.sacubo.org/sacubo_resources/best_practices (02.03.2011.)
- [89] Tilaye, K., Rethinking institutional excellence in Ethiopia: adapting and adopting the balanced scorecard (BSC) model, *Journal of Business and Administrative Studies*, 2(1): 22-53, 2010.
- [90] Vatanawood, W.; Rivepiboon, W. Formal Specification Synthesis for Relational Database Model. *International journal of intelligent systems*, 19: 159-175, 2004.
- [91] VIDL.biz, posebno izdanje 2009., str.5
- [92] Vrček, N., Brumec, J., Nastavni materijali za predmet Stanje i razvoj ERP sustava, Sustav za e-učenje na FOI, 2010.
- [93] Vuković, A., Džambas, I., Blažević, D., Razvoj erp-koncepta i ERP-sustava, *Engineering Review*, 27(2): 37-45, 2007.
- [94] Wagner, E. L., Newell, S.: „Best for whom?: the tension between „best practice“ ERP packages and diverse epistemic cultures in a university context, *The Journal of Strategic Information Systems*, 13: 305-328, , 2004.
- [95] Wang, W., Tolk, A., Wang, W., The Levels of Conceptual Interoperability Model: Applying Systems Engineering Principles to M&S, *Proceedings of the 2009 Spring Simulation Multiconference (SpringSim '09)*. Society for Computer Simulation International, San Diego, CA, USA, , 168:1-168:9, 2009.
- [96] Ward, J., Peppard J., *Strategic Planning for Information Systems*, John Wiley, New York, 2002.
- [97] Yakovlev, I. V., An ERP Implementation and Business Process Reengineering at a Small University, *Educause Quarterly*, 25(2): 52-57, 2002.
- [98] Yugopuspito, P., Araki, K. Transformational Object-Relational Database Model in FormalMethods, *Transactions of Information Processing Society of Japan*, 42(5): 71-80, 2001.
- [99] Zhai, L., Zhang, S., The Feature Model of general ERP System for Discrete Manufacturing Industry, *Proceeding of the International Conference on Electronic Commerce and Business Intelligence*, 12-15, Beijing, PR China, 2009.

U sklopu disertacije autorica je objavila sljedeće znanstvene radove i prezentirala preliminarne rezultate:

- Tomičić-Pupek, K., Determining semantic similarity of IT systems based on the comparison of their graphical data models, *Journal of Information and Organizational Sciences*, 34(2): 211-220, 2010.
- Tomičić-Pupek, K., Strahonja V., ERP implementation approach selection, based on a process classification model, *Proceedings of the 2nd Symposium on Business Informatics in Central and Eastern Europe*, Stefan Ioan Nitchi (ur.). Oestereichische Computer Gesellschaft, Wien, Austria: 279-287, 2011.

Bazična dokumentacijska kartica na hrvatskom jeziku

DD (FOI)

Tekući broj:

Sveučilište u Zagrebu

UDK: 005.932:378.1(043.3)

Doktorska disertacija

Sustavi planiranja i upravljanja resursima visokih učilišta

Katarina Tomičić-Pupek

Fakultet organizacije i informatike, Varaždin, Hrvatska

U radu je analizirana primjena osnovnih koncepata sustava planiranja i upravljanja resursima (*engl. Enterprise Resource Planning – ERP Systems*) te su određeni koncepti koji su u strukturnom i semantičkom smislu slični u različitim područjima primjene ERP sustava, a koji su specifični za visoka učilišta. Zatim je provedena sistematizacija i klasifikacija postojećih ERP sustava te analizirati struktura ERP sustava za visoka učilišta.

U nastavku rada su analizirani odabrani objavljeni referentni modeli primjene ERP sustava u visokim učilištima, te je izrađen referentni model podataka i procesa sustava planiranja i upravljanja resursima visokih učilišta. Nakon toga je provjerena usklađenost modela procesa sa najboljom svjetskom praksom i zakonskom regulativom.

U završnom dijelu rada su istražene razine i modeli interoperabilnosti ERP sustava visokih učilišta s već implementiranim informacijskim sustavima.

Rad nije objavljen.

Voditelj rada: Prof.dr.sc. Vjeran Strahonja

Povjerenstvo za ocjenu: Prof.dr.sc. Josip Brumec

Prof.dr.sc. Vesna Bosilj Vukšić

Prof.dr.sc. Vjeran Strahonja

Povjerenstvo za obranu: Prof.dr.sc. Josip Brumec

Prof.dr.sc. Vesna Bosilj Vukšić

Prof.dr.sc. Vjeran Strahonja

Datum obrane: 17.10.2011.

Datum promocije:

Rad je pohranjen na Fakultetu organizacije i informatike u Varaždinu.

(stranica 242, slika 64, tablica 32, bibliografskih jedinica 99, original na hrvatskom jeziku)

K. Tomičić-Pupek

DD (FOI)

Tekući broj:

UDK: 005.932:378.1(043.3)

1. Sustavi planiranja i upravljanja resursima
visokih učilišta

ERP sustavi za visoka učilišta
Referentni model procesa visokih učilišta
Referentni model podataka

I. Tomičić-Pupek, K.

II. Fakultet organizacije i informatike, Varaždin,
Republika Hrvatska

Bazična dokumentacijska kartica na engleskom jeziku

DD (FOI)

Current file number:

University of Zagreb

UDC: 005.932:378.1(043.3)

Doctoral dissertation

Systems for Planning and Resource Management at Higher Education Institutions

Katarina Tomičić-Pupek

Faculty of Organization and Informatics, Varaždin, Croatia

In this doctoral dissertation an analysis of the application of enterprise resource planning systems (ERP systems) basic concepts has been conducted and it has been determined which concepts are in the structural and semantic sense similar in different ERP implementations, and which are specific to higher education implementations. Further, the systematization and classification of existing ERP systems is proposed, followed by an analysis of the structure of ERP systems for higher education.

In next sections selected and published ERP systems in higher education reference models have been analyzed and data and process reference models for higher education in Croatia were proposed. Further, it has been tested if process models are in accordance with best practice models and legislation.

In the final section of the dissertation different interoperability levels and models between ERP systems and other implemented information systems have been discussed.

The thesis was not published.

Supervisor: Prof.dr.sc. Vjeran Strahonja

Appointed members for evaluation of dissertation: Prof.dr.sc. Josip Brumec

Prof.dr.sc. Vesna Bosilj Vukšić

Prof.dr.sc. Vjeran Strahonja

Appointed members for oral examination: Prof.dr.sc. Josip Brumec

Prof.dr.sc. Vesna Bosilj Vukšić

Prof.dr.sc. Vjeran Strahonja

Oral examination: 17.10.2011.

Degree conferred:

The thesis is deposited at the Library of the Faculty of Organization and Informatics, Varaždin.

(pages 242, pictures 64, tables 32, references 99, original in Croatian language)

K. Tomičić-Pupek

DD (FOI)

Number:

UDC: 005.932:378.1(043.3)

1. Systems for Planning and Resource
Management at Higher Education Institutions

ERP system for Higher education Institutions
Higher education process reference model
Data Reference model

I. Tomičić-Pupek, K.

II. Faculty of Organization and Informatics,
Varaždin, Republic of Croatia

ŽIVOTOPIS

Katarina Tomičić-Pupek

Datum i mjesto rođenja:

Sveučilište u Zagrebu

11.01.1979., Brčko, BiH

Fakultet organizacije i informatike Varaždin

Kućna adresa:

Pavlinska 2, Varaždin

Fabijanska 16A, Varaždin

Tel: 042/390 865

Tel: 098/821162

Fax: 042/213 413

E-mail: ktomicic@foi.hr

OBRAZOVANJE

2007. –

Poslijediplomski doktorski studij na Sveučilištu u Zagrebu, Fakultetu organizacije i informatike, Varaždin

2003. – 2007.

Poslijediplomski znanstveni studij na Sveučilištu u Zagrebu, Fakultetu organizacije i informatike, Varaždin

1998. – 2003.

Dodiplomski studij na Fakultetu organizacije i informatike Varaždin (smjer: Informacijski sustavi)

1994. – 1998.

Gimnazija Varaždin (prirodoslovno-matematički smjer)

1992. – 1994

Osnovna škola Albert Schweitzer u Fellbachu, SR Njemačka

1985. – 1992.

Osnovna škola u Brčkom, RBiH

ZAPOSLENJA

2006. -

Sveučilište u Zagrebu, Fakultet organizacije i informatike, Varaždin

2003.-2006.

KORIS d.o.o. (savjetnik za primjenu ICT u poslovanju)

ZVANJE:

2003.

Diplomirani informatičar

OSTALE AKTIVNOSTI:

Radila na 11 projekata u području strateškog planiranja informacijskih sustava uz primjenu suvremenih CASE-alata, strateškog razvoja informacijsko-komunikacijske tehnologije i mjerenja organizacijskih performansi. Autor / koautor je 6 znanstvenih i 9 stručnih radova.

Popis znanstvenih i stručnih radova

Znanstveni radovi

- **Tomičić-Pupek, K.**, Strahonja, V., ERP implementation approach selection, based on a process classification model, Proceedings of the 2nd Symposium on Business Informatics in Central and Eastern Europe, Stefan Ioan Nitchi (ur.), Wien, Austria, Oesterreichische Computer Gesellschaft, 2011., p. 279-287
- **Tomičić-Pupek, K.**, Determining semantic similarity of IT systems based on the comparison of their graphical data models, Journal of Information and Organizational Sciences, 34 (2), Faculty of Organization and Informatics, Varaždin, 2010., p. 211-220
- Tomičić Furjan, M., Dobrović, Ž., **Tomičić-Pupek, K.**: E-government Training for Public Sector Employees, International Journal of Multidisciplinary Thought, 1(2), USA, 2010, p. 20-29
- **Tomičić-Pupek, K.**, Tomičić Furjan, M., Dobrović, Ž.: Criteria Definition for Implementing Digital Archives in Distributed Organizations - A Case Study, Proceedings of the 20th Central European Conference on Information and Intelligent Systems CECIIS 2009, Varaždin, 2009.
- Dobrović, Ž., Brumec, J., **Tomičić-Pupek K.**: Designing the Document Management System: Metamodeling Approach, 16th International Conference on Information and Intelligent Systems IIS 2005, Varaždin, Proceedings of IIS 2005, pp. 211-220, Fakultet organizacije i informatike, Varaždin, 2005.
- Vrček, N., Kermek, D., **Tomičić, K.**: Document management systems in public administration. 14th International Conference on Information and Intelligent Systems IIS2003, Varaždin, Proceedings of IIS 2003, pp. 155-163, Fakultet organizacije i informatike, Varaždin, 2003.

Stručni radovi

- Dobrović, Ž., **Tomičić-Pupek, K.**, Tomičić, M.: IDEF1X informacijski modeli, Zbornik radova konferencije CASE 20, Opatija 2008.
- **Tomičić-Pupek, K.**, Tomičić, M., Brumec, J.: Paradigme o modeliranju poslovnih procesa i razvoju informacijskih sustava, Zbornik radova konferencije CASE 19, Opatija, 2007.

- Dobrović, Ž., Brumec, J., **Tomičić-Pupek, K.**: Načela IT menadžmenta, Zbornik radova savjetovanja CASE 19, Opatija, 2007.
- **Tomičić-Pupek, K.**, Brumec, J.: Motiviranje organizacije dekompozicijom ciljeva, CASE 18 Zbornik radova konferencije, Opatija, 2006.
- **Tomičić-Pupek, K.**, Dobrović, Ž.: Analiza poslovnih zahtjeva koji utječu na modeliranje sustava za upravljanje dokumentacijom, CASE 17 Zbornik radova konferencije, Opatija, 2005.
- Dobrović, Ž., **Tomičić-Pupek, K.**: Poslovni značaj kataloga dokumenata, CASE 17 Zbornik radova konferencije, Opatija, 2005.
- **Tomičić, K.**: Modeliranje tokova u poslovnoj tehnologiji i informacijskom sustavu, Konferencija CASE 16, Opatija, 2004.
- Vrčec, N., Kermek, D., **Tomičić, K.**: Nema puta naokolo, Infotrend, Zagreb, 2003.
- **Tomičić, K.**, J. Brumec: Usporedna analiza upper-end CASE alata ARIS i Cool:Biz, Konferencija CASE 15, Opatija, 2003.